


UNIVERSIDADE FEDERAL DO PARANÁ

CAROLINA MEDUNA BAZIEWICZ

ANÁLISE DE UMA METODOLOGIA DE CLASSIFICAÇÃO DE SÉRIES TEMPORAIS
PARA DEFINIÇÃO DOS MÉTODOS DE PREVISÃO

CURITIBA

2019



CAROLINA MEDUNA BAZIEWICZ

ANÁLISE DE UMA METODOLOGIA DE CLASSIFICAÇÃO DE SÉRIES TEMPORAIS
PARA DEFINIÇÃO DOS MÉTODOS DE PREVISÃO

Dissertação apresentada ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia da Universidade Federal do Paraná, Setor de Tecnologia e Ciências Exatas, como requisito para obtenção do título de Mestre em Ciências.

Área de Concentração: Programação Matemática

Orientador: Prof. Dr. Cassius Tadeu Scarpin

CURITIBA

2019

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

B363a

Baziewicz, Carolina Meduna

Análise de uma metodologia de classificação de séries temporais para definição de métodos de previsão [recurso eletrônico] / Carolina Meduna Baziewicz. – Curitiba, 2019.

Dissertação - Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-Graduação em Métodos Numéricos em Engenharia, 2019.

Orientador: Cassius Tadeu Scarpin .

1. Análise de séries temporais. 2. Boylan, Classificação de. 3. Syntetos, Classificação de. 4. Previsão. I. Universidade Federal do Paraná. II. Scarpin, Cassius Tadeu. III. Título.

CDD: 519.55

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS EXATAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO MÉTODOS NUMÉRICOS
EM ENGENHARIA - 40001016030P0

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **CAROLINA MEDUNA BAZIEWICZ** intitulada: **Análise de uma Metodologia de Classificação de séries Temporais para definição de Métodos de Previsão**, sob orientação do Prof. Dr. CASSIUS TADEU SCARPIN, que após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 30 de Agosto de 2019.


CASSIUS TADEU SCARPIN


Presidente da Banca Examinadora (UNIVERSIDADE FEDERAL DO PARANÁ)


EDUARDO ALVES PORTELA SANTOS

Avaliador Externo (PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ)


JULIO CÉSAR NIEVOLA

Avaliador Externo (PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ)


ANSELMO CHAVES NETO

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

AGRADECIMENTOS

Dedico este trabalho a Deus, pelo dom da vida e pelas ricas bênçãos concedidas para que eu chegasse até aqui. Obrigada Pai por ter me guiado durante este período de intensa transformação e re-significado.

Gostaria de agradecer a todos que de alguma forma contribuíram com o desenvolvimento deste trabalho. Foram professores, amigos e familiares que me acompanharam nesta trajetória marcante em minha vida.

Agradeço em especial aos meus pais por sempre terem me incentivado a seguir os caminhos do conhecimento e do trabalho árduo. Vocês são para mim grandes exemplos de força, simplicidade, liderança e perseverança. Tenho orgulho da nossa essência e de ser quem eu sou graças a vocês. Agradeço também ao meu irmão Otávio pelo carinho e torcida.

Um agradecimento muitíssimo especial ao meu noivo Fábio, que me fortaleceu de maneira sem igual nos meus momentos mais difíceis e entrou de cabeça nesse desafio, me ajudando de maneira ativa durante todo o desenvolvimento do trabalho. Só você sabe tão bem o que tudo isso significou para mim e para nós. Essa conquista é nossa!

Um agradecimento ímpar ao meu orientador Cassius, por toda a confiança e cumplicidade ao longo de todos esses anos em que estivemos trabalhando juntos. Me faltam palavras para transmitir a admiração e consideração que tenho por você. Obrigada por ter acreditado em mim por vezes muito mais do que eu própria acreditava, e por transmitir tamanha energia positiva. Será difícil não estar mais tão perto.

Durante a maior parte desta fase eu estive trabalhando em jornada dupla. Agradeço com carinho aos meus chefes Sérgio Lourenço e Paulo Henrique Buschinelli por serem grandes incentivadores de pessoas e terem aberto portas para o meu desenvolvimento. Foi uma grande sorte ter vocês no meu caminho!

Por fim, agradeço aos amigos queridos que fizeram verdadeira torcida por mim. Em especial à Bianca, Angelita, Maria, Elisângela, Giovana e Letícia. Vocês são maravilhosas! Agradeço a todos os colegas do GTAO, com os quais tive o prazer e alegria de trabalhar e também dividir momentos de batalha e crescimento.

A todos fica aqui registrado meu muito obrigada!

“**Eu sou o meu único obstáculo.** Cada vez que me supero é a mim que venço.
Não nasci para ser mais, melhor, menos, nem pior do que ninguém, mas para vencer
os meus limites. Não concorro em nada com ninguém.

Eu sou o meu desafio. ”

(Autor desconhecido)

“Àquele que é capaz de fazer **infinitamente mais** do que tudo o que pensamos ou
pedimos, de acordo com o seu poder que opera em nós. ”

Efésios 3:20

RESUMO

Um dos desafios para estruturar uma metodologia robusta de previsão e controle de estoques é a escolha dos métodos de previsão. Neste trabalho foi realizada uma análise crítica da metodologia de classificação de Syntetos e Boylan (2005) no que tange a escolha dos métodos de previsão para itens de reposição de estoque. Tal metodologia sugere que as séries do tipo *slow-moving*, errática e *lumpy* sejam previstas pelo método de Aproximação de Syntetos e Boylan (SBA), e que as séries do tipo *smooth* sejam previstas pelo método de Croston. A metodologia foi testada em dados reais de venda de 9.339 produtos de uma rede do setor supermercadista. Para ampliar a abrangência e contribuição da análise, foram utilizados quinze métodos de previsão, três indicadores de desempenho, três estratégias de previsão e diferentes perspectivas de análise. A análise foi estruturada com base em três elementos principais: a comparação entre os métodos de previsão – pela quantidade de vitórias conquistadas e pelo erro de previsão; a comparação entre as estratégias de previsão; e a comparação dos resultados obtidos com os trabalhos correlatos da literatura. Os resultados mostram que a classificação de Syntetos e Boylan não garantiu a melhor escolha do método de previsão para os dados utilizados, pois os métodos SBA e Croston foram superados por outros métodos em termos de desempenho, especialmente na estratégia 3. Nenhum método foi totalmente superior perante os demais, mas todos se mostraram capazes de fornecer boas previsões, em maior ou menor quantidade de séries. Para as estratégias 1 e 2, os métodos TLSaz, Naive e SBJ obtiveram melhor desempenho geral, enquanto na estratégia 3 o método ARIMA obteve maior destaque. De modo geral, a estratégia 2 é a que registrou menor amplitude geral nos erros de previsão, seguido da estratégia 1 e depois da estratégia 3. Por fim, conclui-se que a busca por uma metodologia de classificação robusta e universal ainda é um grande desafio para esta área de pesquisa. De fato, este tema não tem recebido atenção o suficiente da comunidade científica, haja vista os benefícios diretos que poderiam ser adquiridos desta iniciativa.

Palavras-chave: Classificação de demanda. Métodos de Previsão. Syntetos e Boylan. Itens de reposição.

ABSTRACT

One of the biggest challenges to structure a robust inventory control methodology is the choice of forecasting methods. This paper presents a critical analysis of the classification methodology of Syntetos and Boylan (2005) regarding the choice of forecasting methods for spare parts. Their methodology proposes that slow-moving, erratic and lumpy series should be predicted with Syntetos and Boylan Approximation method (SBA), while smooth series should be predicted by Croston's method. This procedure was tested on a real sales dataset of 9,339 products from a supermarket chain. In order to broaden the scope and contribution of this paper, fifteen forecasting methods, three performance indicators, three forecasting strategies and different analysis perspectives were used. The analysis was structured according to three main elements: the comparison across forecasting methods – the amount of victories of each method and the forecast error; the comparison across forecasting strategies; and the results obtained compared to related works in the literature. The results evidence that the Syntetos and Boylan classification did not guarantee the choice of the best forecasting method for the data used, as long as the SBA and Croston methods were surpassed by other methods in terms of performance, especially in strategy 3. No method was found to be absolutely superior when compared to others, but all were able to provide good forecasts in higher or lesser number of series. For strategies 1 and 2, the TLSaz, Naive and SBJ methods had better overall performance, while in strategy 3 the ARIMA method was more prominent. Overall, strategy 2 has the lowest forecasting error amplitude, followed by strategy 1 and strategy 3. Finally, the search for a robust and unique classification methodology is still a great challenge in this research area. In fact, this issue has not received enough attention from the scientific community as it should, given the direct benefits that could be gained from this initiative.

Keywords: Demand classification. Forecasting Methods. Syntetos and Boylan. Spare Parts.

LISTA DE ILUSTRAÇÕES

FIGURA 1	– EXEMPLO DE SÉRIE TEMPORAL	22
FIGURA 2	– CATEGORIAS DE MÉTODOS DE PREVISÃO	25
FIGURA 3	– CONFIGURAÇÃO TÍPICA DE UMA REDE RBF	38
FIGURA 4	– CLASSIFICAÇÃO DE WILLIAMS	45
FIGURA 5	– CLASSIFICAÇÃO DE SYNTETOS E BOYLAN	48
FIGURA 6	– FLUXOGRAMA DA METODOLOGIA CIENTÍFICA	57
GRÁFICO 1	– QUANTIDADE DE EMPATES VS. TOLERÂNCIA AO EMPATE	61
GRÁFICO 2	– DISTRIBUIÇÃO DOS TIPOS DE SÉRIE POR UNIDADE TEMPORAL	63
GRÁFICO 3	– DISPERSÃO CV^2 X ADI DAS SÉRIES POR UNIDADE TEMPORAL	64
FIGURA 7	– DIAGRAMA DE VENN PARA O TRATAMENTO DOS DADOS	68
GRÁFICO 4	– CV^2 X ADI DADOS TRATADOS – SEMANAL	68
GRÁFICO 5	– DISTRIBUIÇÃO DOS TIPOS DE SÉRIE PARA OS DADOS TRATADOS	69
GRÁFICO 6	– QUANTIDADE GERAL DE VITÓRIAS POR MÉTODO	71
GRÁFICO 7	– QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 0%, ESTRATÉGIA = 1)	73
GRÁFICO 8	– QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 0%, ESTRATÉGIA = 2)	75
GRÁFICO 9	– QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 0%, ESTRATÉGIA = 3)	76
GRÁFICO 10	– QUANTIDADE DE VITÓRIAS X DEMANDA MÉDIA	79
GRÁFICO 11	– BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 1)	81
GRÁFICO 12	– BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 2)	83
GRÁFICO 13	– BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 3)	84
GRÁFICO 14	– COMPARAÇÃO DO ERRO POR ESTRATÉGIA, ID E TIPO DE SÉRIE	86
GRÁFICO 15	– QUANTIDADE GERAL DE VITÓRIAS TODOS OS IDS (ESTRATÉGIA = 1)	104
GRÁFICO 16	– QUANTIDADE GERAL DE VITÓRIAS TODOS OS IDS (ESTRATÉGIA = 2)	105
GRÁFICO 17	– QUANTIDADE GERAL DE VITÓRIAS TODOS OS IDS (ESTRATÉGIA = 3)	105
GRÁFICO 18	– QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 0%, ESTRATÉGIA = 1)	106

GRÁFICO 19 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 0%, ESTRATÉGIA = 2).....	107
GRÁFICO 20 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 0%, ESTRATÉGIA = 3).....	108
GRÁFICO 21 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 0%, ESTRATÉGIA = 1).....	109
GRÁFICO 22 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 0%, ESTRATÉGIA = 2).....	110
GRÁFICO 23 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 0%, ESTRATÉGIA = 3).....	111
GRÁFICO 24 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 5%, ESTRATÉGIA = 1).....	112
GRÁFICO 25 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 5%, ESTRATÉGIA = 2).....	113
GRÁFICO 26 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 5%, ESTRATÉGIA = 3).....	114
GRÁFICO 27 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 5%, ESTRATÉGIA = 1).....	115
GRÁFICO 28 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 5%, ESTRATÉGIA = 2).....	116
GRÁFICO 29 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 5%, ESTRATÉGIA = 3).....	117
GRÁFICO 30 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 5%, ESTRATÉGIA = 1).....	118
GRÁFICO 31 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 5%, ESTRATÉGIA = 2).....	119
GRÁFICO 32 – QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 5%, ESTRATÉGIA = 3).....	120
GRÁFICO 33 – BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MAE:MEAN, ESTRATÉGIA = 1).....	121
GRÁFICO 34 – BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MAE:MEAN, ESTRATÉGIA = 2).....	121
GRÁFICO 35 – BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MAE:MEAN, ESTRATÉGIA = 3).....	123
GRÁFICO 36 – BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 1).....	124

GRÁFICO 37 – BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 2).....	125
GRÁFICO 38 – BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 3).....	126
GRÁFICO 39 – ERRO TABELADO POR TIPO DE SÉRIE (ID = MAEMEAN, ESTRATÉGIA = 1).....	127
GRÁFICO 40 – ERRO TABELADO POR TIPO DE SÉRIE (ID = MAEMEAN, ESTRATÉGIA = 2).....	127
GRÁFICO 41 – ERRO TABELADO POR TIPO DE SÉRIE (ID = MAEMEAN, ESTRATÉGIA = 3).....	127
GRÁFICO 42 – ERRO TABELADO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 1)	128
GRÁFICO 43 – ERRO TABELADO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 2)	129
GRÁFICO 44 – ERRO TABELADO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 3)	129
GRÁFICO 45 – ERRO TABELADO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 1).....	130
GRÁFICO 46 – ERRO TABELADO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 2).....	130
GRÁFICO 47 – ERRO TABELADO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 3).....	130

LISTA DE TABELAS

TABELA 1	– DISTRIBUIÇÃO DA QUANTIDADE DE ZEROS POR UNIDADE TEMPORAL	64
TABELA 2	– HISTOGRAMA DO VOLUME DE VENDA	65
TABELA 3	– MÉDIA DOS TEMPOS COMPUTACIONAIS (SEGUNDOS)	87
TABELA 4	– COMPARAÇÃO DAS ESTRATÉGIAS 1 E 3 - MASE.....	88
TABELA 5	– COMPARAÇÃO DAS ESTRATÉGIAS 1 E 3 - MAE:MEAN	89
TABELA 6	– COMPARAÇÃO DAS ESTRATÉGIAS 1 E 3 - MSE.....	89
TABELA 7	– QUANTIDADE DE VITÓRIAS POR MÉTODO – MSE ESTRATÉGIA 1 VENCE A 3	90
TABELA 8	– QUANTIDADE DE VITÓRIAS POR MÉTODO – MSE ESTRATÉGIA 3 VENCE A 1	91
TABELA 9	– QUANTIDADE DE EMPATES POR MÉTODO – MSE.....	92
TABELA 10	– QUANTIDADE DE VITÓRIAS POR MÉTODO – MASE ESTRATÉGIA 1 VENCE A 3	132
TABELA 11	– QUANTIDADE DE VITÓRIAS POR MÉTODO – MASE ESTRATÉGIA 3 VENCE A 1	132
TABELA 12	– QUANTIDADE DE EMPATES POR MÉTODO – MASE.....	133
TABELA 13	– QUANTIDADE DE VITÓRIAS POR MÉTODO – MAE:MEAN ESTRATÉGIA 1 VENCE A 3.....	133
TABELA 14	– QUANTIDADE DE VITÓRIAS POR MÉTODO – MAE:MEAN ESTRATÉGIA 3 VENCE A 1.....	134
TABELA 15	– QUANTIDADE DE EMPATES POR MÉTODO – MAE:MEAN	134

LISTA DE QUADROS

QUADRO 1 – CLASSIFICAÇÃO DE EAVES E KINGMAN.....	46
QUADRO 2 – INDICADORES DE DESEMPENHO	54
QUADRO 3 – MÉTODOS VS. ESTRATÉGIAS MATRIZ DE POSSIBILIDADES	59
QUADRO 4 – RESUMO DA QUANTIDADE GERAL DE VITÓRIAS – PRIMEIRO LUGAR POR CATEGORIA.....	72
QUADRO 5 – RESUMO DAS QUANTIDADES DE VITÓRIAS POR TIPO DE SÉRIE.....	77
QUADRO 6 – RESUMO DOS RESULTADOS DE TRABALHOS CORRELATOS NA LITERATURA	93
QUADRO 7 – RESUMO DOS RESULTADOS ENCONTRADOS PARA A QUANTIDADE DE VITÓRIAS.....	94

LISTA DE SIGLAS

ACF	– Função de Autocorrelação (<i>Autocorrelation Function</i>)
ADI	– Intervalo Médio entre demandas (<i>Average Demand Interval</i>)
ARIMA	– Modelo Auto-Regressivo e Integrado de Médias Móveis (<i>Auto-Regressive Integrated Mean Average Model</i>)
ARRSES	– Suavização Exponencial Simples com Taxa de Resposta Adaptativa (<i>Adaptive-response-rate Single Exponential Smoothing</i>)
AW	– Winters Aditivo (<i>Additive Winters</i>)
CV²	– Coeficiente de Variação ao quadrado (<i>Squared Coefficient of Variation</i>)
DES	– Suavização Exponencial Dupla (<i>Double Exponential Smoothing</i>)
EWMA	– Médias Móveis Exponencialmente Ponderada (<i>Exponentially Weighted Moving Average</i>)
GMRAE	– Média Geométrica do Erro Absoluto Relativo (<i>Geometric Mean of the Relative Absolute Error</i>)
GRMSE	– Raiz Geométrica do Erro Quadrático Médio (<i>Geometric Root Mean Square Error</i>)
ID	– Indicador de Desempenho (<i>Performance Indicator</i>)
LTD	– Demanda durante o Lead-Time (<i>Lead-Time Demand</i>)
MAD	– Desvio Absoluto Médio (<i>Mean Absolute Deviation</i>)
MAE	– Erro Absoluto Médio (<i>Mean Absolute Error</i>)
MAE:Mean	– Erro Absoluto Médio dividido pela Média – Hoover (<i>Mean Absolute Error of Hoover</i>)
MAPE	– Erro Percentual Absoluto Médio (<i>Mean Absolute Percentage Error</i>)
MASE	– Erro Absoluto Escalonado Médio (<i>Mean Absolute Scaled Error</i>)
MdAPE	– Mediana do Erro Percentual Absoluto (<i>Median of the Absolute Percentage Error</i>)
MdRAE	– Mediana do Erro Absoluto Relativo (<i>Median Relative Absolute Error</i>)
ME	– Erro Médio (<i>Mean Error</i>)
MPE	– Erro Percentual Médio (<i>Mean Percentage Error</i>)
MRAE	– Erro Absoluto Relativo Médio (<i>Mean Relative Absolute Error</i>)
MSE	– Erro Quadrático Médio (<i>Mean Squared Error</i>)
MW	– Winters Multiplicativo (<i>Multiplicative Winters</i>)
PDA	– Abordagem de Demanda única (<i>Single Demand Approach</i>)

RAE	– Erro Absoluto Relativo (<i>Relative Absolute Error</i>)
RBF	– Redes Neurais com Função de Bases Radiais (<i>Artificial Neural Networks of Radial Basis Function</i>)
RGRMSE	– Raiz Geométrica Relativa do Erro Quadrático Médio (<i>Relative Geometric Root Mean Square Error</i>)
RMSE	– Raiz do Erro Quadrático Médio (<i>Root Mean Squared Error</i>)
SDA	– Abordagem da Demanda no período (<i>Period Demand Approach</i>)
S&B	– Syntetos e Boylan
SES	– Suavização Exponencial Simples (<i>Single Exponential Smoothing</i>)
sMAPE	– Erro Percentual Absoluto Médio Simétrico (<i>Symmetric Mean Absolute Percentage Error</i>)
sMdAPE	– Mediana Simétrica do Erro Percentual Absoluto (<i>Symmetric Median of the Absolute Percentage Error</i>)
SRM	– Modelo de Regressão Sazonal (<i>Seasonal Regression Model</i>)
SSE	– Soma dos Erros Quadráticos (<i>Sum of Squared Error</i>)
TAES	– Suavização Exponencial ajustado por tendência (<i>Trend Adjusted Exponential Smoothing</i>)
TE	– Tolerância ao Empate (<i>Tie Tolerance</i>)
TL	– Tendência Linear (<i>Linear Trend</i>)
TLSaz	– Tendência Linear com Sazonalidade (<i>Linear Trend with Seasonality</i>)
WCDR	– Cálculo ponderado da Taxa de Demanda (<i>Weighted calculation of Demand Rates</i>)
WMA	– Média Móvel Ponderada (<i>Weighted Moving Average</i>)
WRDF	– Regressão Ponderada de Demanda (<i>Weighted Regression Demand Forecasters</i>)

SUMÁRIO

1	INTRODUÇÃO.....	17
1.1.	OBJETIVO DO TRABALHO	18
1.1.1.	Objetivos Gerais	18
1.1.2.	Objetivos Específicos	18
1.2.	JUSTIFICATIVA.....	19
1.3.	LIMITAÇÕES DO TRABALHO	20
1.4.	ESTRUTURA DO TRABALHO.....	21
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1.	SÉRIES TEMPORAIS	22
3.1.	MÉTODOS DE PREVISÃO DE SÉRIES TEMPORAIS	24
3.1.1.	Médias Móveis Simples (MMS).....	27
3.1.2.	Suavização Exponencial Simples (SES).....	27
3.1.3.	Tendência Linear (TL).....	28
3.1.4.	Tendência Linear com Sazonalidade (TLSaz).....	30
3.1.5.	Croston e suas Variantes.....	31
3.1.6.	Bootstrap.....	35
3.1.7.	Redes Neurais com Função de Base Radial (RBF)	37
3.1.8.	Redes Neurais com Função de Base Radial e Tendência (RBFT)	39
3.1.9.	Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA).....	41
3.1.10.	Método “Naive”	43
3.2.	MODELOS DE CLASSIFICAÇÃO DE SÉRIES TEMPORAIS	43
3.2.1.	Esquemas de Classificação para Escolha do Método de Previsão	44
3.3.	INDICADORES DE DESEMPENHO (ID).....	52
3	METODOLOGIA	57
3.4.	ESTRATÉGIAS DE PREVISÃO	58
3.5.	PERSPECTIVAS DE ANÁLISE.....	59
4	DADOS UTILIZADOS.....	62
4.1.	ANÁLISE DESCRITIVA DOS DADOS	62
4.2.	PROPOSTA DE TRATAMENTO DOS DADOS.....	66
4.2.1.	Critério 1 – Menos de seis observações não- nulas	66
4.2.2.	Critério 2 – Dezesesseis observações nulas consecutivas.....	66
4.2.3.	Critério 3 – Análise Espectral para Identificação de Ruído (Periodograma)	67

4.2.4.	Dados Tratados	67
5	RESULTADOS E DISCUSSÃO	70
5.1.	ANÁLISE DE DESEMPENHO DOS MÉTODOS	70
5.1.1.	Quantidade Geral de Vitórias por Método de Previsão	70
5.1.2.	Quantidade de Vitórias por Método de Previsão e Tipo de Série	72
5.1.1.	Quantidade de Vitórias versus Demanda Média	78
5.1.2.	Erro de Previsão por Método	80
5.2.	ANÁLISE COMPARATIVA DAS ESTRATÉGIAS DE PREVISÃO.....	85
5.2.1.	Análise do Erro entre as Estratégias 1, 2 e 3	85
5.2.2.	Comparação Detalhada entre as Estratégias 1 e 3	88
5.3.	COMPARAÇÃO DOS RESULTADOS COM OS TRABALHOS CORRELATOS	92
5.4.	DISCUSSÃO DOS RESULTADOS	94
6	CONSIDERAÇÕES FINAIS	97
6.1.	TRABALHOS FUTUROS	98
	REFERÊNCIAS	100
	APÊNDICES	104
	APÊNDICE A – Quantidade Geral de Vitórias – todos os indicadores de desempenho	104
	APÊNDICE B – Quantidade de Vitórias por Método de Previsão e Tipo de Série	106
	APÊNDICE C – Box Plot do Erro de Previsão por Método e Tipo de Série	121
	APÊNDICE D – Erro de Previsão por Método e Tipo de Série – Tabelado	127
	APÊNDICE E – Comparação Detalhada entre as Estratégias 1 e 3	132

1 INTRODUÇÃO

Em diversos setores, em especial no supermercadista, uma boa gestão dos estoques de produtos tem impacto significativo na satisfação dos clientes. A disponibilidade de produtos nas gôndolas tem papel fundamental para a efetivação da compra, e consequentemente garantir a geração de receita da empresa. Um dos maiores desafios é ter uma boa estimativa da demanda futura dos produtos, para que não haja nem excesso de estoque – gerando custos adicionais à empresa e potencial perda de produtos devido ao prazo de validade dos mesmos – nem falta de estoques – que ocasiona perda do potencial de venda e/ou de credibilidade perante os consumidores.

Diante disso, a busca por metodologias mais completas, melhores técnicas de previsão e modelos gerenciais mais eficientes deve ser constante dentro das organizações que buscam se manter competitivas no mercado. A previsão de demanda é uma atividade importante para a gestão dos estoques, e quanto melhor realizada, maiores os benefícios gerados na cadeia de suprimentos.

Porém, diante de tantas opções, escolher um ou mais métodos de previsão a serem utilizados também é um desafio para aqueles que buscam encontrar o método de previsão ideal para seus dados. Muitos pesquisadores realizam testes com mais de uma técnica para determinar qual delas possui melhor performance para seu conjunto de dados, devido à dificuldade em saber qual técnica possui maior potencial de fornecer uma previsão de qualidade – ou simplesmente escolhem um método arbitrariamente.

São poucos os trabalhos na literatura que discorrem sobre técnicas que auxiliem na escolha do melhor método de previsão a ser utilizado. Por isso, essa é uma linha de pesquisa que tem recebido pouca atenção da comunidade científica levando-se em consideração os benefícios que poderiam ser adquiridos desta iniciativa. (BOYLAN 2008). Além disso, as técnicas existentes ainda não foram amplamente comprovadas – elas são válidas, por exemplo, apenas para uma determinada indústria ou produzem resultados diferentes a depender dos dados utilizados.

Este trabalho foi desenvolvido com o intuito de contribuir na identificação e no desenvolvimento de algumas lacunas existentes nesta linha de pesquisa, através do aplicação e investigação da metodologia de Syntetos e Boylan (2005) em um novo conjunto de dados reais – o setor supermercadista. Para isso, foi selecionada uma ampla gama de métodos de previsão, os quais foram aplicados e avaliados segundo indicadores de desempenho. Os resultados

encontrados foram então comparados com a metodologia escolhida e com os trabalhos correlatos da área.

1.1. OBJETIVO DO TRABALHO

Nesta seção são definidos os objetivos gerais e os objetivos específicos do trabalho.

1.1.1. Objetivos Gerais

Este trabalho possui dois objetivos centrais, definidos a seguir:

- Analisar criticamente a metodologia de classificação de Syntetos e Boylan (2005), utilizando um conjunto de dados reais como objeto de teste.
- Expandir os conhecimentos atuais desta área de pesquisa, através da ampliação da quantidade de métodos de previsão utilizados, escolha dos indicadores de desempenho, e concepção de estratégias de previsão e perspectivas de análise.

1.1.2. Objetivos Específicos

A fim de que o objetivo geral seja alcançado, faz-se necessário satisfazer os seguintes objetivos específicos:

- Dispor de registros históricos reais da área de interesse com quantidade suficiente de dados, de modo a possibilitar a aplicação dos métodos de previsão e posterior análise dos resultados com a qualidade pretendida.
- Realizar um levantamento teórico dos principais métodos de previsão e indicadores de desempenho para séries temporais existentes, com o intuito de realizar uma boa seleção das técnicas a serem utilizadas no trabalho.
- Realizar um levantamento teórico sobre técnicas de classificação existentes na área de interesse, de modo a identificar as lacunas de conhecimento atuais e ampliar a contribuição do trabalho proposto.
- Definir a estratégia geral da previsão, a saber: a unidade de medida da previsão versus unidade de medida dos registros históricos; horizonte de tempo de dados históricos a ser considerado; horizonte de tempo a ser previsto; e estratégia de previsão.

- Implementar computacionalmente os métodos de previsão e os indicadores de desempenho escolhidos e obter os resultados.
- Realizar a análise dos resultados fazendo uso de uma ampla quantidade de gráficos e perspectivas de análise.
- Interpretar os resultados encontrados e compará-los com os trabalhos correlatos da literatura.

1.2. JUSTIFICATIVA

A gestão da cadeia de suprimentos é uma área de elevada complexidade e por isso vem estimulando o desenvolvimento de sistemas inteligentes para auxiliar na tomada de decisões. Um dos desdobramentos necessários para uma boa gestão da logística interna de qualquer empresa é a previsão do volume de vendas. Porém, estruturar uma metodologia robusta de previsão e controle de estoques não é tarefa trivial, a começar pela escolha dos métodos.

A escolha dos métodos de previsão e controle de estoque está diretamente relacionada ao conceito de classificação de diferentes padrões de demanda. As técnicas de classificação existentes se concentram primeiramente em propor a existência de alguns padrões de demanda, e a partir desta classificação sugerir um método de previsão e reposição de estoque para cada categoria. Contudo, a área de desenvolvimento de esquemas de classificação não tem recebido atenção suficiente da comunidade científica. (HEINECKE, 2013) Ao longo das últimas décadas, não houve uma produção científica significativa nesta área. Por isso, há uma falta de orientação sobre quais técnicas devem ser utilizadas para classificar produtos e sobre quais características devem ser levadas em consideração. (KAMPEN et al. 2012). A construção e o aprimoramento de esquemas de classificação necessitam de maior atenção científica, dadas as implicações diretas que as mesmas possuem nas tomadas de decisões empresariais. (SYNTETOS et al. 2009)

Uma das classificações mais difundidas, por exemplo, é a classificação de Syntetos & Boylan (2005), que propõe que as demandas do tipo *smooth* sejam previstas com o método de Croston, e as demandas do tipo errática, *lumpy* e *slow-moving* sejam previstas com o método SBA. Contudo, alguns trabalhos posteriormente publicados que utilizaram tal metodologia revelam que chegaram a conclusões diferentes do proposto, a depender dos dados utilizados. (Mais detalhes no Capítulo 2).

Por isso, é evidente que nesta área ainda existe a necessidade de se realizar uma pesquisa mais aprofundada de outras abordagens de classificação que sejam aplicáveis a qualquer tipo de indústria ou contexto real, com uma precisão exata em relação aos limites entre um tipo de padrão e outro. (BABILONI et al. 2010)

Além disso, ao longo dos anos muitas técnicas de previsão surgiram, tornando necessária uma comparação mais abrangente e atualizada entre as técnicas existentes. Por exemplo, a partir de 2008, surgiram as técnicas baseadas em inteligência artificial e que agora estão em plena ascensão e desenvolvimento. As técnicas estatísticas mais robustas, como por exemplo o ARIMA, foram raramente comparadas com as técnicas mais tradicionais. Embora muitos métodos estejam surgindo, poucos trabalhos têm se preocupado em identificar regiões de supremacia de algum método perante outros já existentes. Neste trabalho, foi realizada uma ampla seleção de métodos de previsão (ao todo foram 15 métodos utilizados), de modo a endereçar este *gap* existente na literatura.

Outro aspecto muito relevante para comparação entre métodos de previsão é forma de mensurar o erro. Existem inúmeros indicadores de desempenho na literatura, porém poucos trabalhos fazem uso de mais de uma métrica e/ou estudam a diferença entre eles. Além disso, são raros os autores que detalham o motivo de escolha da métrica utilizada. Por isso, este é um aspecto ao qual será dado o devido foco ao longo deste trabalho.

Por fim, observa-se que algumas características da metodologia de previsão são expostas de maneira pouco óbvia em grande parte dos trabalhos publicados. Um exemplo disso é o que foi denominado neste trabalho de “estratégia de previsão”, que consiste no detalhamento da forma como foi estruturada a previsão ao longo do horizonte de previsão. Neste trabalho, foram utilizadas três estratégias de previsão, detalhadas de forma clara e comparadas ao final, de forma a contribuir com pesquisadores que estejam interessados nessa linha de pesquisa.

1.3. LIMITAÇÕES DO TRABALHO

A previsão de demanda quando aplicada em contextos reais não é um processo que ocorre de maneira isolada de outras áreas. Esta estimativa está principalmente relacionada à gestão de estoques e políticas de ressuprimento. Dentre os trabalhos levantados na fundamentação teórica, alguns citam que a avaliação integrada do método de previsão e simulação de reposição de estoques além de ser benéfico para o desenvolvimento desta linha de pesquisa, permite avaliar com maior propriedade os métodos escolhidos pois possibilita

estimar o impacto financeiro gerado pelo aumento ou redução do volume dos estoques e das possíveis rupturas geradas. (BACCHETTI & SACCANI, 2012)

Portanto, este ponto é visto como uma oportunidade de continuação desta pesquisa, sendo uma limitação de escopo deste trabalho.

Outra limitação identificada foi a não utilização de outros métodos de previsão existentes, como por exemplo os métodos híbridos (combinação de dois ou mais métodos), o SARIMA, SVM, entre outros. A grande quantidade de métodos de previsão existentes de fato dificulta a análise exaustiva dos mesmos e comparação de todos entre si. Ainda assim, diante dos trabalhos previamente publicados, acredita-se que houve um salto representativo na quantidade de métodos comparados.

1.4. ESTRUTURA DO TRABALHO

O trabalho está dividido da seguinte forma: O Capítulo 2 expõe a fundamentação teórica; o Capítulo 3 discorre sobre a metodologia científica de desenvolvimento; o Capítulo 4 apresenta a análise dos dados utilizados e tratamentos realizados; o Capítulo 5 apresenta os resultados e discussões; e por fim o Capítulo 6 apresenta as considerações finais.

2 FUNDAMENTAÇÃO TEÓRICA


Nesta seção será realizada a fundamentação teórica dos conceitos pertinentes ao desenvolvimento deste trabalho. Primeiramente, será feita uma descrição formal do conceito de séries temporais e de suas principais características. Em seguida, serão delineados os quinze métodos de previsão utilizados neste estudo. Na sequência, serão referenciados os trabalhos prévios e correlatos no tema de classificação de demanda com o foco de promover a escolha do melhor método de previsão. Por fim, são apresentadas as medidas de acurácia mais utilizadas e recomendadas pela literatura.

2.1. SÉRIES TEMPORAIS

O estudo de dados experimentais cuja ocorrência se dá de forma sucessiva no tempo trouxe novos desafios à análise e inferência estatística. Uma das principais premissas para aplicação de diversos métodos estatísticos – que é a garantia de que os dados sejam identicamente e independentemente distribuídos – sofre sérias restrições para as séries temporais, trazendo a necessidade de desenvolvimento de novos métodos. (SHUMWAY & STOFFER, 2011)

A metodologia de análise sistemática através da qual busca-se descrever matematicamente e estatisticamente a maneira como os dados podem estar temporalmente correlacionados recebe o nome de análise de séries temporais. (SHUMWAY & STOFFER, 2011)

FIGURA 1 - EXEMPLO DE SÉRIE TEMPORAL



FONTE: A autora (2019)

As séries temporais podem ser objetos de estudo nas mais diversas áreas de aplicação: finanças, marketing, economia, demografia, ciências sociais, meteorologia, energia, epidemiologia, etc. É possível encontrar muitos exemplos no cotidiano: a taxa de câmbio de uma determinada moeda oscilando a cada dia; a temperatura média mensal registrada em uma cidade; a quantidade de CO₂ emitida pelos veículos de uma região; o número de acidentes ocorridos nas rodovias federais mês a mês; vendas de determinado produto ao longo do tempo.

A ideia básica que orienta o estudo de séries temporais é a premissa de que houve uma causa mais ou menos constante relacionada com o tempo que exerceu influência sobre os dados no passado e que pode continuar influenciando no futuro, ou seja, trata-se de um processo estocástico composto por uma parte sistemática (que pode ser modulada) e por uma parte estocástica (que não se tem acesso). Nesse sentido, surgem alguns conceitos fundamentais para a análise de séries temporais: as definições de *tendência*, *sazonalidade*, *estacionariedade* e *autocorrelação*.

A *tendência* indica o comportamento de uma série de “longo prazo”, isto é, se ela cresce, decresce ou permanece estável e qual a intensidade destas variações. A *sazonalidade* indica variações que se repetem de forma periódica na série, sejam elas positivas ou negativas, de prazos relativamente curtos (um ano ou menos). (EHLERS, 2005)

O conceito de *estacionariedade* é a condição em que a série se desenvolve aleatoriamente no decorrer do tempo em torno de uma média, variância e estrutura de autocorrelação constantes mostrando uma forma de estabilidade (Montgomery e Jennings, 2008). Essa é uma condição comum e importante para aplicação de técnicas de séries temporais. A metodologia de Box & Jenkins se apoia nessas condições. Para o conceito matemático formal de *estacionariedade*, por favor consulte Shumway and Stoffer (2011) – págs. 22 e 23.

A *autocorrelação* tem o intuito de medir se as observações vizinhas em uma série são dependentes e estão relacionadas entre si no tempo, contribuindo para a identificação de sazonalidade e também da estacionariedade ou não-estacionariedade da série. Esta estatística é obtida através do cálculo do coeficiente de autocorrelação (ACF – *Autocorrelation Function*), através do qual a série original é defasada k períodos (também conhecido como *lag*) e comparada consigo mesma.

Segundo Montgomery and Jennings (2008), a ACF é dada pelo conjunto dos coeficiente de autocorrelação ρ_k , $k = 0, 1, 2, \dots$, de forma que:

$$\rho_k = \frac{E[(y_t - \mu)(y_{t+k} - \mu)]}{\sqrt{E[(y_t - \mu)^2]E[(y_{t+k} - \mu)^2]}} = \frac{Cov(y_t, y_{t+k})}{Var(y_t)} = \frac{\gamma_t}{\gamma_0} \quad (1)$$

Onde:

y_t = observação no instante t

y_{t+k} = observação no instante $t + k$

μ = média das observações

γ_t = função de autocovariância

As séries temporais são muitas vezes não-estacionárias devido à presença de tendência, ciclos, padrões sazonais ou outros comportamentos não-estacionários. Por isso, alguns métodos de previsão usam transformações matemáticas para “estacionarizar” uma série.

Séries que apresentam sazonalidade e/ou tendência necessitam que esses efeitos sejam eliminados num primeiro momento, e depois colocados na previsão final. Ao retirar os efeitos de tendência e sazonalidade, sobra uma componente conhecida como componente irregular ou aleatória da série. Para possibilitar a rápida identificação dessas características na série estudada recomenda-se que seja realizada a análise gráfica da mesma.

Outras formas de transformações comuns são: tomar diferenças sucessivas; aplicar função logarítmica para estabilizar variâncias e/ou deflacionar. (Para mais detalhes, por favor consulte Montgomery and Jennings (2008) e Shumway and Stoffer (2011)).

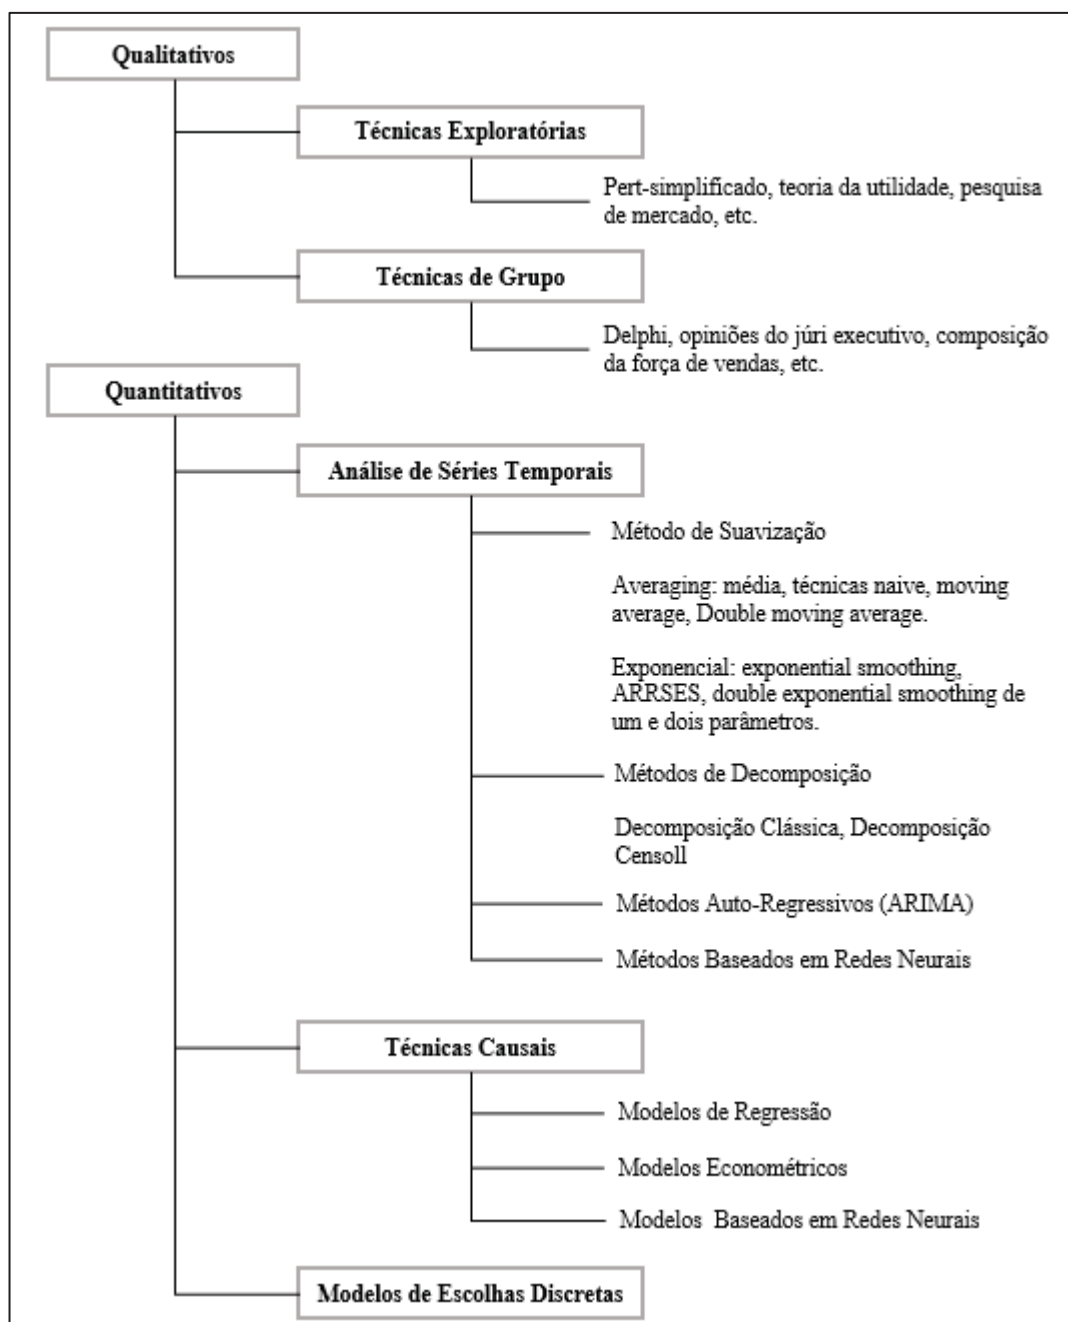
Todos estes conceitos apresentados são importantes na identificação das características das séries e dos elementos que as compõem, o que por sua vez possibilita um melhor design e seleção do(s) método(s) de previsão.

3.1. MÉTODOS DE PREVISÃO DE SÉRIES TEMPORAIS

A tarefa de escolher um método de previsão para utilizar em séries temporais não é trivial. Para conseguir um modelo que represente com qualidade o comportamento real dos dados é necessário testar diferentes técnicas e avaliar qual delas apresenta a melhor performance, segundo algum indicador de desempenho.

Existem duas grandes categorias de métodos de previsão: os métodos qualitativos e os métodos quantitativos (Figura 2). Os métodos qualitativos se baseiam na subjetividade, pois os dados são julgados por especialistas com capacidade técnica para opinar através da intuição a demanda futura. Já os métodos quantitativos utilizam técnicas matemáticas e estatísticas para realizar a estimativa da demanda futura.

FIGURA 2 - CATEGORIAS DE MÉTODOS DE PREVISÃO



FONTE: Scarpin (2012)

Existem três principais categorias de métodos quantitativos: os métodos temporais, causais e o por escolhas discretas (ou simulação). Há uma diferença fundamental entre os métodos temporais e os causais. Os temporais utilizam apenas o histórico dos dados no modelo, de forma que a demanda futura será uma projeção dos eventos ocorridos no passado, sem considerar a influência de outras variáveis. Por outro lado, os métodos causais produzem um resultado que é justamente obtido através da influência de outras variáveis que “explicam” o comportamento da demanda.

Ao utilizar técnicas de previsão para aplicações em contextos reais, é crucial identificar qual característica é mais predominante no contexto da ocorrência da demanda: se existem variáveis externas que precisam ser consideradas, ou se a forma mais adequada seja realmente considerar a realização histórica. De forma geral, quando há excessivos agentes externos, dificilmente enumeráveis e que não “expliquem” estatisticamente uma porção razoável da demanda, a forma mais segura de realizar a previsão seja através de alguma técnica temporal.

Neste trabalho, foram utilizados dados de uma empresa do setor supermercadista. Nesse contexto, podem existir efeitos externos como por exemplo fatores econômicos, atuações de marketing e propaganda, e influência de competidores. Porém, no entendimento dos autores, tais efeitos não são predominantes no comportamento das vendas da grande maioria dos produtos, e do mesmo modo não seria possível mapeá-los com fidedignidade. Por este motivo, os autores optaram por utilizar técnicas temporais nos dados levantados.

Montgomery and Jennings (2008) propõem uma abordagem genérica com alguns passos para a modelagem de métodos para previsão de séries temporais. Segundos os autores, o estudo começa plotando a demanda num horizonte de tempo e determinando suas características básicas. Depois, é necessário eliminar os efeitos sazonais e de tendência, através de diferenciação ou transformações, para gerar “resíduos” estacionários. Posteriormente, aplicam-se diversos modelos de previsão nos resíduos, e determina-se qual o melhor método. Então, valida-se o modelo escolhido através de alguma técnica de amostragem ou *cross-validation*. Para realizar a previsão com o modelo escolhido, aplica-se novamente os efeitos sazonais e de tendência previamente retirados. Por fim, se estabelece um procedimento para monitorar o desempenho do método previsão.

A abordagem proposta por Montgomery sugere uma análise detalhada e individualizada por série. Embora esta seja a “melhor prática” a ser adotada para *design* e seleção dos métodos, analisar individualmente as séries não é a proposta deste trabalho – até mesmo porque seria inviável prever mais de 3.500 produtos desta maneira.

Neste trabalho, o foco é compor uma “carteira” de métodos capazes de se adaptar aos mais variados comportamentos de demanda, desde os mais simples (como os modelos de suavização exponencial) até os mais elaborados (modelo auto-regressivo integrado de médias móveis e redes neurais artificiais). Alguns métodos são intrinsicamente capazes de identificar tendência, sazonalidade, e realizar as transformações necessárias nos resíduos, enquanto outros não. Esta decisão foi intencional, pois o interesse está em verificar se os métodos considerados mais “simples” também têm o potencial de conseguir bons resultados, mesmo se aplicados em suas versões mais tradicionais.

Além disso, há o interesse em analisar o desempenho geral dos métodos para séries com diferentes características, de forma a compará-los e tecer análises que possam ajudar outros pesquisadores na tarefa de escolher métodos de previsão para seus dados.

A seguir, cada um dos quinze métodos de previsão utilizados neste trabalho será discutido com maior nível de detalhe: Médias Móveis Simples, Suavização Exponencial Simples, Tendência Linear, Tendência Linear com Sazonalidade, Croston e Variantes (SBA, SBJ, SY, TSB, HES), *Bootstrap*, Redes Neurais Artificiais de Bases Radiais e variação com tendência, Modelo Auto-Regressivo Integrado de Médias Móveis e *Naive*.

3.1.1. Médias Móveis Simples (MMS)

O método de previsão de Médias Móveis Simples, ou em inglês *Moving Average*, é o mais elementar dentre os modelos de previsão quantitativos existentes. Ele consiste em calcular a média simples das k últimas ocorrências da série observada. (PEINADO & GRAEML, 2007).

Seja D_t a demanda ocorrida no período t , então a previsão de demanda P_{t+1} para o período $t+1$ será dado por:

$$P_{t+1} = \frac{D_t + D_{t-1} + D_{t-2} + \dots + D_{t-k}}{k}, \quad k > 0 \quad (2)$$

Para prever a demanda do período $t+2$, deve-se “mover” a série um passo à frente, de maneira que P_{t+2} é dado por:

$$P_{t+2} = \frac{D_{t+1} + D_t + D_{t-1} + \dots + D_{t-k+1}}{k}, \quad k > 0 \quad (3)$$

Quanto maior o valor de k , maior será a influência das demandas mais antigas sobre a previsão. Entretanto, menor será a capacidade de reação da previsão às oscilações mais recentes. É interessante comentar que foi implementada uma rotina de otimização no parâmetro k , na qual este foi testado exaustivamente para determinação do valor que resultasse em menor erro.

3.1.2. Suavização Exponencial Simples (SES)

Para realizar o cálculo da previsão do período seguinte (P_{t+1}) através do SES, três informações são necessárias: a demanda real ocorrida no período anterior D_t , a previsão de demanda do mês anterior P_t e a constante de suavização α . (WILLEMAIN, 2004). A equação (4) define a previsão de demanda pelo SES:

$$P_{t+1} = \alpha D_t + (1 - \alpha)P_t \quad 0 \leq \alpha \leq 1 \quad (4)$$

A constante de suavização α funciona como um fator de ponderação que permite atribuir maior ou menor peso à demanda real D_t ou à previsão do mês anterior P_t . O impacto que a constante de suavização produz pode ser resumido da seguinte maneira: (MAKRIDAKIS, 1997)

- α próximo de 1: Maior peso devido as mudanças recentes na série e menor poder de suavização;
- α próximo de 0: Menor peso devido as mudanças recentes na série e maior poder de suavização.

Apesar da constante de suavização poder ser arbitrariamente escolhida, ela pode ser estimada de maneira otimizada através de testes exaustivos (testar todos os possíveis valores avaliando o erro de previsão segundo alguma medida de erro). Neste trabalho, este procedimento foi realizado, de forma a testar todos as possíveis constantes de suavização entre 0 e 1,0 com três casas decimais, e assim determinar qual a constante que minimiza o erro entre os valores previstos e reais.

Para mais detalhes em relação ao método, por favor consulte Willemain, Smart, and Schwarz (2004) .

3.1.3. Tendência Linear (TL)

O método da Tendência Linear consiste em determinar a reta que melhor se “ajusta” a um conjunto de pontos de modo que a soma dos quadrados dos resíduos (isto é, as distâncias verticais entre os pontos e a reta encontrada) seja mínimo. (KENNEY & KEEPING, 1962). Na TL existe somente uma variável explicativa (ou variável independente) e uma variável de resposta (ou variável dependente). Para descrever a relação linear entre estas variáveis, é necessário, obrigatoriamente, estimar dois parâmetros: o coeficiente linear e o coeficiente angular da reta. (KENNEY & KEEPING, 1962)

Considere Y a variável dependente, X a variável independente, α o coeficiente linear, β o coeficiente angular e ϵ o resíduo (erro) de cada observação em relação à reta. O modelo do valor de Y em função de X no instante t é dado por:

$$Y_t = \alpha + \beta \cdot X_t + \epsilon_t \quad (5)$$

2.1.3.1. Estimando os Coeficiente Alfa e Beta

Dado um conjunto de n pontos (x_t, y_t) , onde $t = 1, 2, \dots, n$, o objetivo é encontrar a equação X de modo a minimizar a soma dos quadrados dos resíduos do modelo de tendência linear. A função de minimização dos resíduos pode ser dada por:

$$\min Q(\alpha, \beta) = \sum_{t=1}^n (\widehat{\epsilon}_t)^2 = \sum_{t=1}^n (y_t - \hat{\alpha} - \hat{\beta} \cdot X_t)^2 \quad (6)$$

Aplicando-se o método dos Mínimos Quadrados Ordinários (MQO) na equação acima estima-se os coeficientes $\hat{\alpha}$ e $\hat{\beta}$. Seja \bar{x} a média dos valores de x , \bar{y} a média dos valores de y , $\overline{x^2}$ a média dos valores de x elevados ao quadrado e \bar{x}^2 o valor da média dos valores de x elevado ao quadrado. Seja ainda r_{xy} o coeficiente de correlação da amostra entre x e y , s_y o desvio padrão de y , e s_x o desvio padrão de x .

Os valor de $\hat{\alpha}$ e $\hat{\beta}$ podem ser dados por:

$$\hat{\beta} = \frac{\sum_{t=1}^n (x_t - \bar{x})(y_t - \bar{y})}{\sum_{t=1}^n (x_t - \bar{x})^2} = \frac{\sum_{t=1}^n x_t \cdot y_t - \frac{1}{n} \sum_{t=1}^n x_t \sum_{t=1}^n y_t}{\sum_{t=1}^n (x_t^2) - \frac{1}{n} (\sum_{t=1}^n x_t)^2} \quad (7)$$

$$\hat{\beta} = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{x^2} - \bar{x}^2} = \frac{Cov[x, y]}{Var[x]} = r_{xy} \frac{s_y}{s_x} \quad (8)$$

$$\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x} \quad (9)$$

O coeficiente angular estimado da reta ($\hat{\beta}$) é igual à correlação entre x e y multiplicado pela razão de desvios padrão destas variáveis. O coeficiente linear estimado ($\hat{\alpha}$) por sua vez, pode ser obtido depois de calculado o coeficiente angular.

É interessante comentar que o modelo de tendência linear sofre influência de uma propriedade de médias, de que a soma de seus desvios em relação às observações é nula. Outra propriedade interessante é que a reta de tendência passa obrigatoriamente pelo centro de massa dos dados (\bar{x}, \bar{y}) .

É importante comentar que, além disso, o método prevê algumas propriedades estatísticas importantes, como a suposição de normalidade dos resíduos, a garantia de estimadores não-enviesados, e a possibilidade de cálculos de intervalos de confiança. (para mais detalhes, consultar Kenney and Keeping (1962)).

3.1.4. Tendência Linear com Sazonalidade (TLSaz)

A metodologia de previsão utilizando tendência linear com sazonalidade é fundamentada em analisar separadamente a série histórica sob duas perspectivas: tendência e sazonalidade (MEDEIROS & BIANCHI, 2009). Essa análise é realizada de forma sequencial e organizada. Medeiros e Bianchi (2009) descrevem formalmente este processo em seis etapas:

1. Escolher uma série histórica representativa;
2. Definir um ciclo temporal que representa a sazonalidade, ou seja, a periodicidade em que os incrementos e reduções da série histórica se repetem. Então, calcular os índices de sazonalidade de cada período;
3. Remover a sazonalidade através dos índices de sazonalidade para cada período.
4. Retirado o fator sazonal da série, analisar a série sob a perspectiva de tendência, aplicando o método de tendência linear;
5. Com o produto do passo 4, a equação linear que define a série, calcular os valores previstos para o(s) período(s) seguinte(s);
6. Aplicar os índices de sazonalidade ao(s) período(s) previsto(s);

Um dos maiores desafios para utilizar este método é a correta identificação do ciclo da sazonalidade, pois é preciso saber a frequência de ocorrência da mesma para que os índices possam ser calculados. Para identificação do ciclo da sazonalidade, pode-se fazer uso de técnicas estatísticas (conforme previamente comentado), ou do uso da experiência e conhecimento do contexto de ocorrência da demanda. Vale lembrar que o ciclo está diretamente relacionado à unidade temporal dos dados.

Devido à proposta de caráter generalista deste trabalho, e à grande quantidade de produtos abordados concomitantemente, foi adotado um conceito único geral para o ciclo sazonal. A ideia base para definição deste conceito foi observar a ocorrência dos picos de maior demanda ao longo do mês, que supostamente aconteciam nos dias próximos aos pagamentos de salários (início ou final de mês, ou próximo ao quinto dia útil). Este comportamento foi confirmado através de análises gráficas de algumas das séries utilizadas.

No entendimento dos autores, uma abordagem válida é considerar que existem cinco padrões distintos de semanas: existem quatro semanas “comuns” ao longo do mês – 1 semana de início de mês, 2 intermediárias e 1 no final do mês – e existe aquela semana “dividida” onde há término de um mês e início de outro. É justamente nestas semanas compartilhadas entre

meses que há maior expectativa de aumento de demanda devido ao efeito sazonal do aumento do poder de compra do consumidor.

Outras possíveis ocorrências de sazonalidade (anual, semestral ou trimestral) foram descartadas devido à limitação da quantidade de dados históricos (um ano), ou por não se esperar representatividade das mesmas (análise qualitativa).

Após o reconhecimento do ciclo sazonal, é necessário calcular os índices de sazonalidade. A título de exemplo, vamos supor que o ciclo de sazonalidade seja igual a 5 períodos. Isso quer dizer que o padrão de demanda se repete a cada cinco observações e, portanto, deverão existir também 5 diferentes índices de sazonalidade - um para cada período do ciclo.

Existem diversas formas de calcular o índice de sazonalidade. Uma delas é calcular primeiramente a variação positiva ou negativa de cada observação em relação à reta de tendência. Calcula-se esta variação para todas as observações do histórico. Então, para estimar o índice de sazonalidade, basta então fazer a média dos índices sazonais das observações equiparáveis em termos do ciclo sazonal. (Para mais detalhes sobre como calcular o índice de sazonalidade, por favor consulte Lisboa and Gomes (2018) – páginas 81-83)

3.1.5. Croston e suas Variantes

O método de Croston (1972) foi a técnica pioneira para previsão de séries intermitentes (séries com alta incidência de ocorrências nulas), sendo assim considerado o método de “estado-da-arte” nesta área. O método foi criado com o intuito de solucionar alguns problemas que os métodos de suavização exponencial enfrentavam para prever demandas intermitentes, utilizando para isso estimadores independentes para o tamanho e frequência de demanda. (CROSTON, 1972)

Em sua formulação original, o método de Croston se preocupa em estimar a cada período o intervalo entre demandas não-nulas I_t e a demanda esperada das ocorrências não-nulas S_t . Estas duas estimativas são atualizadas iterativamente a cada período e fazem parte do cálculo da previsão M_t , que é a razão entre tais estimativas.

O método consiste em avaliar se no período imediatamente anterior houve demanda nula ou não nula D_t , e atualizar as estimativas S_t e I_t , de forma que:

$$\text{Se } D_t = 0 \quad (10)$$

$$S_{t+1} = S_t$$

$$I_{t+1} = I_t$$

$$M_{t+1} = M_t$$

$$q = q + 1$$

$$\text{Se } D_t \neq 0$$

$$S_{t+1} = \alpha * D_t + (1 - \alpha) * S_t$$

$$I_{t+1} = \beta * q + (1 - \beta) * I_t$$

$$M_{t+1} = \frac{S_{t+1}}{I_{t+1}}$$

$$q = 1$$

Onde:

D_t = demanda real ocorrida no período t

M_t = previsão de demanda para o período t

S_t = estimativa da demanda média para demanda não – nula no período t

I_t = estimativa do intervalo médio entre demandas não – nulas no período t

q = intervalo de tempo desde a última demanda não – nula

α = constante de alisamento exponencial para demandas

β = constante de alisamento exponencial para intervalo entre demandas

É interessante observar que se o horizonte de tempo possui somente demandas não-nulas, os cálculos do método de Croston recaem consequentemente no método de Suavização Exponencial Simples.

Um ponto negativo do método de Croston surge quando há muitas observações sucessivas de demanda nula. A previsão somente muda de valor após o término da sequência de valores nulos, ou seja, quando há ocorrência de alguma demanda não-nula.

As premissas básicas para aplicar o método de Croston são: estacionariedade da série; o tamanho da demanda e os intervalos entre as demandas possuem média e variância constantes e são mutuamente independentes; o processo de geração de demandas segue uma distribuição de Bernoulli; o intervalo entre demandas segue distribuição geométrica; e o tamanho das demandas segue distribuição normal. (BOYLAN & SYNTETOS, 2008)

Contudo, essas premissas sempre foram questionadas e consideradas pouco realísticas pela comunidade acadêmica. Com o passar dos anos, outros autores propuseram pequenas adaptações e surgiram variações do método original.

Syntetos and Boylan (2001) demonstraram que o método de Croston é positivamente enviesado e propuseram uma adaptação para corrigir este problema. Este viés não se deve propriamente à premissa de estacionariedade ou do fato da distribuição dos intervalos entre demandas serem geometricamente distribuídos, mas sim se deve ao valor utilizado na constante de suavização. (SYNTETOS & BOYLAN, 2005)

Este método adaptado, também conhecido como Syntetos e Boylan Approximation (SBA) é praticamente idêntico ao método original de Croston, com exceção da inserção de um coeficiente corretor da previsão da demanda M_{t+1} somente para $D_t \neq 0$, de modo que:

$$M_{t+1} = \left(1 - \frac{\beta}{2}\right) * \frac{S_{t+1}}{I_{t+1}} \quad (11)$$

O coeficiente utilizado no SBA para eliminação do viés funciona bem para demanda intermitente, porém o método continua tendencioso para demandas não intermitentes. Este problema é mitigado pelo próprio Syntetos (2001), através de inserção de um termo de correção no denominador da demanda M_{t+1} somente para $D_t \neq 0$ de forma que:

$$M_{t+1} = \left(1 - \frac{\beta}{2}\right) * \frac{S_{t+1}}{I_{t+1} - \frac{\beta}{2}} \quad (12)$$

Outro estudo em relação aos fatores de correção do viés foi proposto por Shale, Boylan, and Johnston (2006). Os autores propõem um fator de correção exato para utilizar quando o intervalo entre demandas segue distribuição exponencial negativa ou *Erlang*. (Características estas que podem ser úteis quando o método de previsão é associado a um sistema de reposição de estoques). Os autores sugerem manter as médias dos intervalos entre demandas e dos tamanhos das demandas, seja por média aritmética ou por média ponderada.

Para derivar o fator de correção exato, os autores assumem a premissas de que a série pode ser tratada como localmente estacionária, mas a estimativa dos parâmetros permite a não-estacionariedade.

De maneira similar ao SBA, o SBJ é idêntico ao método de Croston original, exceto pela inserção de um coeficiente que multiplica a previsão M_{t+1} , de modo que:

$$M_{t+1} = \left(1 - \frac{\beta}{2 - \beta}\right) * \frac{S_{t+1}}{I_{t+1}} \quad (13)$$

Estas três variantes propostas (SBA, SY e SBJ) foram capazes, portanto, de eliminar o viés que o método de Croston original possuía e contribuir para a melhoria dos métodos de previsão de demanda intermitente existentes.

Em 2011, surge uma nova proposta de Teunter, Syntetos, and Babai (TSB). O intuito do TSB foi eliminar completamente o efeito de viés e contemplar o conceito de obsolescência (que pode ser entendido como perecibilidade) de maneira pioneira. Diferentemente do método de Croston, que é baseado na atualização do intervalo entre demandas não-nulas, o TSB é baseado na atualização da probabilidade de demandas não-nulas. O TSB suaviza exponencialmente a probabilidade de demanda a cada período, e o tamanho da demanda a cada ocorrência de demanda não-nula.

Sejam as seguintes variáveis:

Y_t = demanda real ocorrida no período t

Y'_t = estimativa da demanda média por período no final do período t
para o período $t + 1$

z_t = tamanho da demanda atual no período t

z'_t = estimativa do tamanho da demanda no final do período t

p_t = indicador de ocorrência de demanda para o período t , de forma que:

$$p_t = \begin{cases} 1 & \text{se a demanda ocorre no período } t (Y_t > 0) \\ 0 & \text{caso contrário} \end{cases}$$

p'_t = estimativa da probabilidade de ocorrência de demanda no final do período t

α, β = constantes de suavização ($0 \leq \alpha, \beta \leq 1$)

O método TSB é tal que:

$$\text{Se } p_t = 0 \tag{14}$$

$$p'_t = p'_{t-1} + \beta (0 - p'_{t-1})$$

$$z'_t = z'_{t-1}$$

$$Y'_t = p'_t z'_t$$

$$\text{Se } p_t = 1$$

$$p'_t = p'_{t-1} + \beta (1 - p'_{t-1})$$

$$z'_t = z'_{t-1} + \alpha (z_t - z'_{t-1})$$

$$Y'_t = p'_t z'_t$$

É interessante comentar que o autor realizou uma investigação numérica e verificou que o TSB pode ser aplicado para séries estacionárias e não-estacionárias, mas sugeriu que as

constantes de suavização fossem estudadas mais a fundo em pesquisas futuras. O autor sugere ainda que o TSB seja testado empiricamente com outros métodos de previsão.

Em 2014, surge outra proposta de método que também endereça o conceito de obsolescência, mas que volta a ser parecido com o formato do método de Croston original: o método *Hyperbolic-Exponential Smoothing* (HES) ou Suavização Hiperbólica Exponencial. (PRESTWICH, 2014). O HES surge como uma quinta alternativa ao método de Croston e demais variantes previamente publicadas, trazendo baixo nível de viés e alta acurácia de previsão tanto para demandas intermitentes quanto para não intermitentes.

O principal aspecto deste método é o fato da demanda decair hiperbolicamente durante os períodos de demanda zerada (uma propriedade derivada de inferência Bayesiana), o que proporciona ao método uma rápida velocidade de reação a ocorrências de demanda nula e o torna competitivo perante outros métodos.

A modificação em relação ao método de Croston se dá pela introdução de um termo aditivo na previsão M_{t+1} quando $D_t = 0$. Utilizando as mesmas variáveis e a definição do método de Croston original, o método HES é tal que:

$$M_{t+1} = \frac{S_{t+1}}{I_{t+1}} + \frac{\beta q}{2} \quad (15)$$

O autor compara o HES ao TSB e constata que o HES é mais robusto que o TSB para realizar a suavização da demanda, enquanto o TSB é melhor para endereçar a característica de obsolescência. Segundo o autor, ambos os métodos funcionam bem tanto para séries estacionárias quanto séries não estacionárias.

3.1.6. Bootstrap

O conjunto de técnicas de reamostragem denominada “*Bootstrapping*” ou “*Bootstrap*” surgiu pela primeira vez em 1979, quando foi proposto por Bradley Efron. Uma década depois, estas técnicas foram utilizadas pela primeira vez para estimativa da distribuição da demanda e para controles de estoques (BOOKBINDER & LORDAHL, 1989)

Um trabalho bastante reconhecido para a aplicação deste método é o trabalho proposto por Willemain, Smart, and Schwarz (2004). O método proposto pelos autores foi testado em 28.000 itens provenientes de dados reais de nove companhias, e obteve resultados superiores ao método de alisamento exponencial simples e método de Croston.

O método é baseado na construção de uma matriz de transição (processo Markoviano de dois estados) e na aplicação de pequenas perturbações nos dados históricos (processo denominado *jittering*, traduzido como “agitação” neste trabalho)

O método é composto por um conjunto de passos:

1. Obter dados históricos na unidade temporal desejada (ex. dia, semana, mês)
2. Estimar as probabilidades de transição (demandas nulas e não-nulas) através de um modelo de *Markov*.
3. Em relação à última demanda observada, utilize o modelo de *Markov* para gerar valores binários ao longo do horizonte de previsão.
4. Substitua cada demanda não-zerada por um valor sorteado aleatoriamente com reposição do conjunto de observações históricas não zeradas.
5. “*Jitter*” ou “Agite” as demandas substituídas.
6. Some os valores ao longo do horizonte de previsão para obter um valor previsto para o LTD.
7. Repita os passos 3-7 muitas vezes.
8. Ordene e utilize a distribuição resultante dos valores do LTD.

A forma como a demanda é “agitada” consiste em aplicar um fator aleatório baseado na distribuição normal padrão de média 0 e desvio padrão igual a 1. Seja X^* um dos valores históricos sorteados aleatoriamente, e seja Z um desvio padrão normal aleatório. Para calcular a demanda “agitada” Y , fazemos:

$$Y = 1 + \text{int}\{X^* + Z\sqrt{X^*}\} \quad (16)$$

$$\text{Se } Y \leq 0, \text{ então } Y = X^* \quad (17)$$

Se o cálculo da agitação resultar em um valor menor do que zero (o que é impossível em termos de previsão), utiliza-se o próprio valor sorteado. Caso contrário, a agitação é realizada e a demanda é atualizada.

Embora na descrição dos passos não fique evidente qual é o número de repetições necessárias, os autores realizam 1.000 vezes o procedimento. Por isso, este foi também o valor adotado neste trabalho. Essa quantidade de replicações necessárias (o que pode ser caro computacionalmente), torna evidente que o método Bootstrap tem um objetivo particular: estimar a distribuição de demanda durante o horizonte de previsão, conceito conhecido como LTD (*Lead-Time Demand*). Este é um conceito importante quando o método de previsão é associado a um sistema de reposição de estoques.

Neste trabalho, o objetivo se restringe a fazer uma avaliação da performance do método de previsão. Por isso, foi necessário escolher uma dentre as muitas replicações feitas para ser a previsão considerada como resposta do método. Para isso, selecionou-se uma replicação cuja soma dos elementos fosse no máximo 5% distante da média de todas as replicações (média do LTD).

É importante comentar que todos os métodos de Bootstrap são baseados na premissa de que os dados utilizados são estacionários ou poderiam ser facilmente transformados em estacionários. Portanto, séries que possuem fortes traços de tendência e/ou sazonalidade podem ser um problema. (WILLEMAIN, 2004)

3.1.7. Redes Neurais com Função de Base Radial (RBF)

As redes neurais artificiais (RNA) são técnicas de inteligência artificial que podem ser empregadas em diversos problemas relacionados às engenharias e ciências, como por exemplo, em aproximação de funções, controle de processos, reconhecimento de padrões, agrupamento de dados, otimização de sistema e, de maneira mais relevante para este trabalho, sistemas de previsão. (SILVA, 2010)

O princípio de funcionamento das redes neurais é inspirado no funcionamento do cérebro humano, que é composto por um conjunto de unidades de processamento (neurônios artificiais) que são interligados por um grande número de conexões (vetores/matrizes de pesos sinápticos). A rede formada por estes elementos possui características importantes como a adaptação por experiência, e capacidade de aprendizado e generalização. (HAYKIN, 2001)

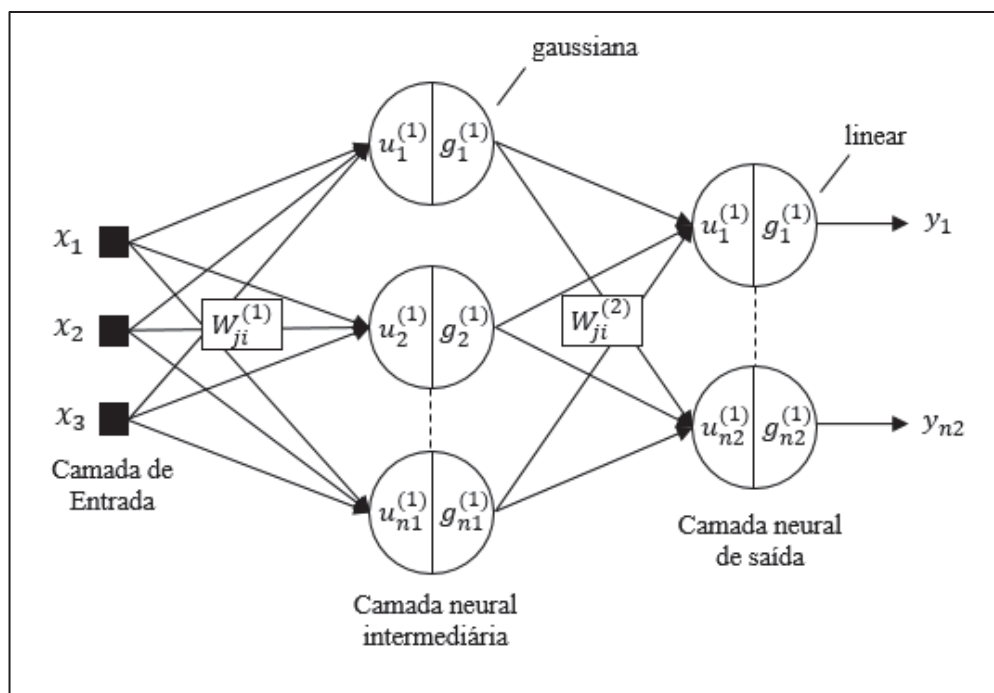
O design de uma rede neural passa necessariamente pela determinação da topologia da rede (*feed-forward*¹ ou recorrentes), pela escolha da função de ativação (p.e. linear, degrau, logística, tangente hiperbólica, gaussiana, etc.), pelo tipo de treinamento (supervisionado ou não-supervisionado) e pela estimativa dos demais parâmetros eventualmente necessários em cada técnica. (SILVA, 2010)

Dentre as inúmeras técnicas existentes, uma técnica bastante reconhecida para a previsão de séries temporais são as Redes Neurais com Função de Base Radial (RBF) ou *Artificial Neural Networks of Radial Basis Function*. (SCARPIN, 2012)

¹ Uma rede neural *feed-forward* é uma rede neural artificial em que as conexões entre os nós não formam um ciclo. Por isso, é diferente das redes neurais recorrentes.

As RBFs são redes do tipo *feed-forward* de camadas múltiplas (entrada, intermediária e saída) compostas por apenas uma camada intermediária e que geralmente utilizam função de ativação do tipo gaussiana (que é uma função de base radial). Estas redes utilizam unidades com campos receptivos locais (*local receptive fields*), nos quais as unidades que recebem estímulos de entrada podem responder à apenas parte destes estímulos. (SCARPIN, 2012)

FIGURA 3 - CONFIGURAÇÃO TÍPICA DE UMA REDE RBF



FONTE: Silva, Spatti, and Flauzino (2010).

O treinamento da RBF é tipicamente realizado através de aprendizado híbrido (supervisionado e não-supervisionado) e se dá através do cálculo iterativo da posição do centro e da largura dos campos receptivos (fase não-supervisionada), e dos pesos entre a camada escondida e a camada de saída (fase supervisionada). Existem diferentes técnicas para se determinar a posição do centro e a largura dos campos receptivos e para minimizar os erros provenientes dos pesos sinápticos. Para mais detalhes, por favor consulte Scarpin (2012).

Um dos parâmetros mais importantes de serem estimados na RBF quando aplicado à previsão de séries temporais é a dimensão do padrão de entrada. Este valor corresponde à quantidade de ocorrências na matriz de entrada, a qual está diretamente ligada ao número de atrasos unitários no tempo que se deseja aplicar, e ao tamanho fixo do vetor de entrada. Outro parâmetro a ser definido em conjunto com o padrão de entrada, é a quantidade de dados a serem

utilizados para teste (que geralmente varia percentualmente entre 10% a 40% dos padrões de entrada) (SCARPIN, 2012)

Outro parâmetro igualmente importante é a dimensão dos campos receptivos, o qual é responsável por determinar o ajuste da linearidade em torno da série temporal. Este parâmetro precisa ser equilibrado (nem demasiadamente pequeno nem grande) de forma a proporcionar um patamar acertado de generalização. (SCARPIN, 2012)

A fundamentação teórica da RBF foi realizada de forma resumida devido ao escopo do trabalho ter foco na comparação entre diversos métodos. Se o leitor estiver interessado em saber mais detalhes técnicos em relação ao design e utilização da RBF, recomendam-se as seguintes referências (Scarpin, 2012), (Silva, Spatti e Flauzino, 2010).

A título de informação, serão descritas todas as características utilizadas no design da RBF neste trabalho, para caso o leitor tenha interesse em reproduzir a técnica:

- Quantidade de observações no histórico: 52 (unidade: semanal), com no mínimo 6 observações não-nulas.
- Dimensão do padrão de entrada: testadas as possibilidades de 1 a 6 (tamanho da entrada), com atraso fixo unitário de 1 período, e adotado o melhor valor.
- Função Gaussiana utilizada na ativação: $z_j(x) = e^{-\|x - u_j\|^2 * BS_{pread}^2}$
- Dimensão do Campo Receptivo: $BS_{pread}^2 = \frac{\sqrt{-\ln(0,5)}}{0,83} \approx 1$
- Método para determinação da localização (centro) dos campos receptivos: algoritmo k-médias (ou *k-mean*)
- Técnica de agrupamento: definido pela menor distância entre um padrão de entrada e o centróide mais próximo.
- Método para minimizar o erro dos pesos sinápticos: método da pseudo-inversa.

3.1.8. Redes Neurais com Função de Base Radial e Tendência (RBFT)

O método aqui referenciado como Redes Neurais com Função de Base Radial e Tendência (RBFT) consiste em um método de previsão híbrido, que utiliza os resultados de ajuste e previsão dos métodos RBF e TL em conjunto.

O conceito base desta versão híbrida e modificada da RBF é a inserção de um elemento de tendência na RBF, através do cálculo de alguns índices de proporção, que são aplicados em cima do ajuste e da previsão do método TL. (SCARPIN, 2012)

Considerando as seguintes variáveis:

$AjTL$ = Vetor de ajuste da série original pelo método TL

$AjRBF$ = Vetor de ajuste da série original pelo método RBF

$AjRBFT$ = Vetor de ajuste da série original pelo método RBFT

$PrevTL$ = Vetor de previsão da série original pelo método TL

$PrevRBF$ = Vetor de previsão da série original pelo método RBF

$PrevRBFT$ = Vetor de previsão da série original pelo método RBFT

$AjTL_{AjRBF}$ = Vetor de ajuste pelo método TL da série ajustada pela RBF

$AjTL_{PrevRBF}$ = Vetor de ajuste pelo método TL da série prevista pela RBF

$Prop_{Aj}$ = Índices de Proporção para o Ajuste

$Prop_{Prev}$ = Índices de Proporção para a Previsão

Considerando que os métodos TL e RBF foram previamente aplicados na série a ser prevista e que se deseja obter o ajuste e a previsão pelo método RBFT:

A. Calcular o ajuste pelo Método RBFT:

- i. Aplicar a TL ao ajuste obtido na aplicação do método RBF na série original ($AjRBF$), registrando o ajuste obtido ($AjRLS_{AjRBF}$).
- ii. Para cada período t do $AjTL_{AjRBF}$, calcular $Prop_{Aj}$ de forma que:

$$Prop_{Aj}(t) = \frac{AjRBF(t)}{AjTL_{AjRBF}(t)} \quad (18)$$

- iii. Para cada período t , calcular o ajuste pela RBFT aplicando a proporção obtida no ajuste obtido na aplicação do método TL na série original ($AjTL$)

$$AjRBFT(t) = Prop_{Aj}(t) * AjTL(t + Dimensão do Padrão)$$

B. Calcular a previsão do Método RBFT:

- i. Aplicar a TL à previsão obtida na aplicação do método RBF na série original ($PrevRBF$), registrando o ajuste obtido ($AjTL_{PrevRBF}$).
- ii. Para cada período t do $AjTL_{PrevRBF}$, calcular $Prop_{Prev}$ de forma que:

$$Prop_{Prev}(t) = \frac{PrevRBF(t)}{AjTL_{PrevRBF}(t)} \quad (19)$$

- iii. Para cada período t , calcular a previsão pela RBFT aplicando a proporção obtida na previsão obtida na aplicação do método TL na série original ($PrevRLS$)

$$PrevRBFT(t) = Prop_{Prev}(t) * PrevTL(t) \quad (20)$$

Pode-se observar que o cálculo do ajuste e da previsão pelo método RBFT são realizados de maneira individualizada, mas a forma de cálculo é essencialmente a mesma.

3.1.9. Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA)

O Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA) foi desenvolvido por George Box e Gwilyn Jenkins (1970), e desde então é considerado pela comunidade científica um dos métodos quantitativos de previsão mais robustos existentes. Ele consiste de uma generalização dos Modelos Auto-Regressivos (AR), Modelos de Médias Móveis (MA) e dos Modelos Auto-Regressivo de Médias Móveis (ARMA) - anteriormente proposto por Peter Whittle em 1951.

Uma das contribuições do ARIMA em relação ao ARMA é o fato de poder ser utilizado tanto em séries estacionárias quando em séries não estacionárias, pois a etapa de diferenciação intrínseca ao método busca a estacionariedade da série.

O ARIMA possui fundamentalmente três conceitos que o definem: *auto-regressão* (de ordem p), *diferenciação* (de ordem d) e *médias móveis* (de ordem q). Para definir o modelo, faz-se uso da notação ARIMA (p, d, q), onde p indica o número de termos auto-regressivos, d o número de vezes que a série deve ser diferenciada e q o número de termos da média móvel. (MONTGOMERY, 2008). Para aplicar o ARIMA é desejável que a série possua mais que 50 elementos.

Um modelo auto-regressivo (AR) busca relacionar uma ocorrência da série temporal com observações passadas da mesma série. Seja uma série de dados Z_t e suas ocorrências ao longo do tempo, o termo constante δ , os parâmetros de auto-regressão a serem estimados $\varphi_1, \varphi_2, \dots, \varphi_p$ e a_t o erro com distribuição gaussiana $a_t \sim N(0, \sigma_a^2)$. Um modelo AR de ordem p descreve a série Z_t da seguinte forma:

$$Z_t = \delta + \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t \quad (21)$$

Um modelo de médias móveis (MA) busca identificar o erro de regressão através dos erros registrados em instantes passados. Seja uma série de dados Z_t , o termo constante μ , os parâmetros de médias móveis a serem estimados $\theta_1, \theta_2, \dots, \theta_q$ e os termos de erro a_t . Um modelo MA de ordem q descreve a série Z_t da seguinte forma:

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (22)$$

A diferenciação consiste em realizar o cálculo da diferença ∇Z_t , onde ∇ é o operador de diferenças, de uma observação da série temporal Z_t em relação à observação imediatamente

anterior. O resultado obtido é uma nova série w_t com $t-1$ observações, que pode ser estacionária. São necessárias d operações consecutivas até que se obtenha uma série estacionária.

$$\nabla Z_t = Z_t - Z_{t-1} = w_t \quad (23)$$

Geralmente, são necessárias apenas uma ou duas etapas de diferenciação, até que a série se torne estacionária. (MORETTIN, 2006). Além disso, a quantidade de vezes que uma série necessita ser diferenciada para que se torne estacionária é conhecida como “ordem de homogeneidade”. (PINDYCK & RUBINFELD, 2004)

A junção dos três conceitos dá origem ao ARIMA, que pode ser expresso na forma de equações de diferenças como:

$$\Delta^d Z_t = W_t = \varphi_1 W_{t-1} + \varphi_2 W_{t-2} + \dots + \varphi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (24)$$

O processo de construção de um modelo ARIMA pode ser descrito por um ciclo iterativo composto por 4 etapas: Identificação, Estimação; Verificação e Previsão. (MORETTIN, 2006).

A primeira etapa consiste na pressuposição de uma classe geral de modelos (AR, MA, ARMA, etc.) e na estimativa da ordem d da série, ou seja, na realização das diferenciações necessárias até que a série se comprove estacionária. Em seguida, ocorre a etapa de estimação dos parâmetros do modelo. Neste trabalho, foi utilizado o algoritmo de Marquardt (1963) para estimativa dos parâmetros, que consiste de uma ferramenta de otimização matemática para estimativa de mínimos quadrados não-lineares. A etapa subsequente consiste na verificação do modelo, a qual consiste em avaliar os resíduos estimados e mensurar a qualidade da previsão gerada. As técnicas mais comumente utilizadas nesta etapa são: teste do periodograma integrado, teste da sobrefixação, comparação das autocorrelações, e teste de Portmanteau. Por fim, a etapa de previsão consiste em colocar o método em uso para previsão e controle.

A fundamentação teórica do ARIMA, similarmente à RBF, foi realizada de forma resumida devido ao escopo do trabalho ter foco na comparação entre diversos métodos. Se o leitor estiver interessado em se aprofundar no método, recomendam-se as seguintes referências: Box, Jenkins, and Reinsel (1970) ou Morettin and Toloi (2006)

A título de informação, serão descritas todas as características utilizadas na construção do ARIMA neste trabalho, para caso o leitor tenha interesse em reproduzir a técnica:

- Quantidade de observações no histórico: 52 (unidade: semanal), com no mínimo 6 observações não-nulas.
- Código realiza até duas diferenciações. ($d \leq 2$)
- É necessário que haja ao menos um termo auto-regressivo ou de médias móveis como condição para se realizar a previsão.

- Coeficientes φ_t e θ_t foram estimados pelo algoritmo *Levenberg-Marquardt*.
- Diferentes valores iniciais para o algoritmo são testados a fim de se considerar uma melhor convergência local (Faixa de Variação: -0,5 a 0,8)

3.1.10. Método “Naive”

O termo “*Naive*” vem do inglês, e significa “ingênuo” ou “tolo”. Este método consiste simplesmente em considerar que a previsão para o próximo período P_{t+1} é igual à demanda real ocorrida no último período D_t . Por se tratar de um método bastante simples e cuja qualidade de previsão esperada é relativamente baixa, ele é bastante utilizado como referência (*benchmark*) para comparação com outros métodos. (MIRANDA, 2014)

3.2. MODELOS DE CLASSIFICAÇÃO DE SÉRIES TEMPORAIS

As séries temporais utilizadas como objetos de estudo em modelos de previsão não raras as vezes representam produtos comercializáveis para os quais há uma cadeia de produção e logística envolvidas. De maneira geral, a quantidade de produtos que são geridos simultaneamente é enorme. Por isso, muitas vezes é necessário definir critérios de classificação e/ou prioridade, de modo a direcionar o fluxo das operações. (KAMPEN, 2012)

Crítérios de classificação podem ser definidos de inúmeras formas, porém sempre estão alinhados à algum objetivo organizacional. Segundo Kampen, Akkerman, and Pieter (2012), um método de classificação pode ser definido com foco em uma das três seguintes áreas: I – gestão de estoques, II - previsão de demanda, e III - estratégias de produção.

O trabalho de Kampen, Akkerman, and Pieter (2012) pode ser considerado um marco importante nesta linha de pesquisa, pois é o primeiro trabalho a realizar uma revisão sistemática das técnicas de classificação existentes até o momento. Ao todo, foram analisados 533 trabalhos, oriundos de 85 revistas científicas, dos quais 45 foram selecionados para um estudo mais aprofundado.

A grande maioria dos trabalhos existentes na literatura que propuseram metodologias de classificação possuem enfoque na gestão de estoques, nos quais, muito comumente, técnicas estatísticas de alto nível são utilizadas de forma integrada às técnicas de gerenciamento de armazéns (determinação de ponto de pedido, estoque de segurança, quantidade de pedido/produção). (KAMPEN, 2012)

Em segundo lugar tem-se trabalhos voltados para a área II – previsão de demanda. O principal benefício de ter um método eficiente de classificação com esse fim é tornar a escolha do método de previsão mais assertiva. Um dos aspectos importantes na seleção do método é o comportamento da demanda ao longo do tempo. A eficiência de diferentes métodos de previsão utilizado é altamente influenciada pelo padrão da demanda do item, isto é, se é regular, intermitente, *slow-moving*, etc. (KAMPEN, 2012)

Sabe-se por exemplo que modelos baseados na abordagem de Box & Jenkins não conseguem fazer distinção de tendência e sazonalidade quando há muitos períodos com demanda zerada (EAVES & KINGSMAN, 2004). Portanto, não seriam os mais adequados para prever demandas de movimentação lenta ou intermitente. Por outro lado, o Método de Croston, ou derivados dele são conhecidos por serem específicos para séries intermitentes. (CROSTON, 1972), (SYNTETOS E BOYLAN, 2010), (KOURENTZES, 2014).

Por fim, o objetivo III – estratégias de produção possui a menor representatividade de produção científica. Em relação às estratégias de produção, assuntos previamente abordados são: definição de canais de distribuição; priorização de clientes; decisões de produção para encomenda ou para estoque; análise de ciclo de vida de produtos, etc. (ver mais em Kampen et al. (2012)).

Neste trabalho, o foco será dado principalmente ao objetivo II - previsão de demanda. Na seção seguinte serão mencionados os trabalhos mais relevantes nesta área.

3.2.1. Esquemas de Classificação para Escolha do Método de Previsão

O trabalho seminal de Williams (1984) foi o primeiro a propor a existência de três diferentes padrões de demanda, a saber: regular (*smooth*), esporádica (*sporadic*), e intermitente (*slow-moving*).

Segundo o autor, a variabilidade da demanda ao longo do horizonte de previsão (LTD – *Lead Time Demand*), é uma característica que pode descrever os diferentes padrões de demandas existentes, contribuindo assim para a escolha do método de previsão e das políticas de reposição de estoques. O autor propõe que a variância do LTD é dada pela soma das suas três parcelas constituintes: a variabilidade no número de ocorrências de demanda, variabilidade do tamanho das ocorrências, e a variabilidade no lead-time de reposição do estoque.

Seja o número de ordens que chegam ao sistema em unidades sucessivas de tempo independentes e identicamente distribuídos (i.i.d.) com média \bar{n} e variância $var(n)$. Seja o tamanho das ordens que chegam i.i.d com média \bar{x} e variância $var(x)$. Seja também o lead-

time de reposição do estoque i.i.d com média \bar{L} e variância $var(\bar{L})$. Então, a variância do LDT pode ser estimada por:

$$var(LDT) = \bar{x}^2 \bar{L} var(n) + \bar{n} \bar{L} var(x) + n^2 \bar{x}^2 var(\bar{L}) \quad (25)$$

Pode-se também escrever a equação (25) em termos do coeficiente de variação de cada termo, tornando-a assim adimensional:

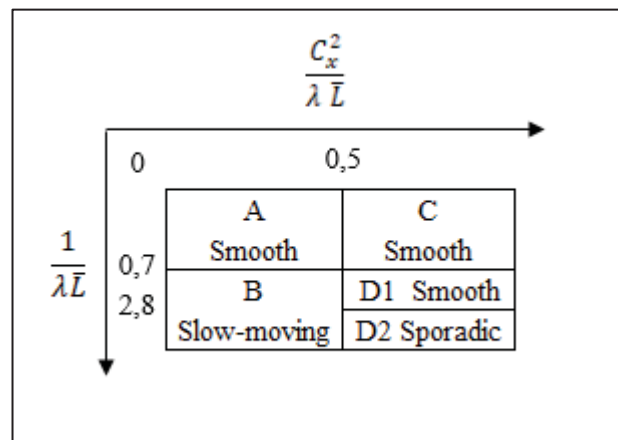
$$C_{LDT}^2 = \frac{C_n^2}{\bar{L}} + \frac{C_x^2}{\bar{n} \bar{L}} + C_L^2 \quad (26)$$

Onde C_n é o coeficiente de variação da distribuição do número de ordens, etc. A equação 26 possibilita que vários métodos sejam utilizados para classificar produtos através da partição de C_{LDT}^2 , dependendo de circunstâncias em particular. Supondo-se por exemplo que a ocorrências de chegada de demandas segue uma distribuição Poisson com média λ , e os lead-times entre demandas sejam constantes, então:

$$C_{LDT}^2 = \frac{1}{\lambda \bar{L}} + \frac{C_x^2}{\lambda \bar{L}} \quad (27)$$

Dessa forma, os produtos podem ser classificados pela soma destas duas parcelas, onde a primeira parcela representa o número médio de lead-times entre demandas, e a segunda parcela é uma medida do grau de “lumpiness” – ou irregularidade da demanda. A Figura 4 abaixo apresenta a proposta final do autor, que se dá através da definição dos “limites” entre as regiões, criando quadrantes distintos.

FIGURA 4 - CLASSIFICAÇÃO DE WILLIAMS



FONTE: A autora (2019).

Williams (1984) salienta que a definição dos limites entre as regiões é uma decisão gerencial e que depende do conjunto de dados que se utiliza. O autor não fornece orientação em

relação à qual método de previsão utilizar em cada categoria de demanda, mas em seu trabalho, utiliza o método de suavização exponencial simples para toda as categorias e apenas cita que o método de Croston pode ser necessário para as categorias C e D1.

Outro trabalho similar de classificação foi o trabalho de Eaves & Kingsman (2004). Segundo os autores, a classificação original proposta por Williams não descrevia satisfatoriamente todos os padrões de demanda existentes. Segundo os autores, há cinco diferentes tipos de demanda: regular (*smooth*), irregular, *slow-moving*, e com intermitência média (*midly intermittent*) ou alta (*highly intermittent*).

QUADRO 1 - CLASSIFICAÇÃO DE EAVES E KINGMAN

Variabilidade do número de ordens	Variabilidade do tamanho de ordem	Variabilidade do Lead-Time	Classificação do Padrão de Demanda
$\leq 0,74$	$\leq 0,10$	-	Regular
$\leq 0,74$	$> 0,10$	-	Irregular
$> 0,74$	$\leq 0,10$	-	Slow-moving
$> 0,74$	$> 0,10$	$\leq 0,53$	Intermitente Médio
$> 0,74$	$> 0,10$	$> 0,53$	Intermitente Alto

FONTE: (Eaves e Kingsman, 2004).

De maneira análoga à Williams, os autores definem os limites entre os tipos de demanda de acordo com os dados utilizados (estoque de peças de reposição da Força Aérea do Reino Unido), pois a classificação não possui um caráter universal. (EAVES & KINGSMAN, 2004). O critério aplicado pelos autores é bastante simples: o primeiro quartil dos dados definiu o limite para a variabilidade do número de ordens (25% dos itens classificados como “Regular” ou “Irregular”). Os demais limites foram definidos pela mediana dos valores restantes.

Os autores aplicam nos dados quatro métodos de previsão de demanda – Croston, SBA, SES e MMS - utilizam três medidas de erro tradicionais – RMSE, MAPE e MAD – agrupam os dados em três unidades temporais – quadrimestral, mensal e semanal – e comparam duas estratégias de previsão – um período à frente e todo o horizonte de demanda. Embora os autores comentem que métodos de Box & Jenkins não são considerados bons para demandas intermitentes, eles não o aplicam para testar sua performance em relação aos demais métodos utilizados.

Os resultados evidenciam que não houve um método único que pode ser considerado o melhor em todos os testes: O SBA foi o melhor segundo o MAPE para previsão de um período à frente, enquanto o MMS foi o melhor segundo o MAD. O SES dominou para previsão de todo o horizonte de previsão. A diferença entre o Croston e o SBA foi pequena para os dados

semanais em particular. Fica evidente que mesmo os métodos mais simples, como o SES e MMS podem ser os melhores métodos para as demandas do tipo intermitente e *slow-moving*, enquanto o método SBA e o Croston, originalmente indicado para demanda intermitente, podem ser bons para demanda regular (*smooth*) e irregular. (EAVES, 2002)

Segundo os autores, a identificação do melhor método de previsão para ser utilizado em um sistema de reposição de produtos não é tão objetiva quando se utilizam as métricas tradicionais para medida de performance. As medidas de erro por si só podem ser questionáveis, pois as medidas percentuais não podem ser calculadas quando a demanda é nula, e diferentes conclusões podem surgir dependendo de qual medida é utilizada. Além disso, a escolha da estratégia para a previsão e mensuração do erro pode impactar na análise e são questões abertas para debate: se é feita a previsão de apenas um período à frente ou do período total, e se o erro é mensurado no período completo ou apenas quando ocorre demanda. (EAVES & KINGSMAN, 2004).

É interessante comentar que os autores posteriormente simulam o funcionamento de um sistema de reposição de estoques utilizando todos os métodos de previsão e contabilizando os custos de estoques gerados por cada método. A conclusão a que se chega é que o método SBA é o que produz menores custos de estoque para todos os padrões de demanda. (EAVES & KINGSMAN, 2004). Ou seja, realizar a simulação do sistema de reposição de estoques pode auxiliar na identificação do melhor método de previsão.

Um dos trabalhos mais citados na literatura² acerca deste tema foi publicado um ano depois por Syntetos and Boylan (2005). Segundo os autores, a arbitrariedade na escolha dos limites entre os tipos de padrão de demanda propostos por (Williams, 1984) e Eaves & Kingsman (2004) pode colocar em descrédito o potencial de aplicar tais modelos em contextos diferentes dos já previamente estudados.

Os autores propõem um novo método de classificação baseado em duas métricas inéditas: o intervalo médio entre demandas não-nulas (ADI – *Average Inter-Demand Interval*) e o coeficiente de variação ao quadrado das demandas não-nulas (CV²). Enquanto o ADI é uma medida de intermitência, o CV² é uma medida de variabilidade do tamanho das demandas.

Os autores propõem quatro tipos de demanda, a saber:

- **“*Smooth* – ou regular”** – possui baixa variabilidade na demanda e baixo nível de intermitência.

² 147 publicações registradas na plataforma Scopus – consulta em 06/07/2019

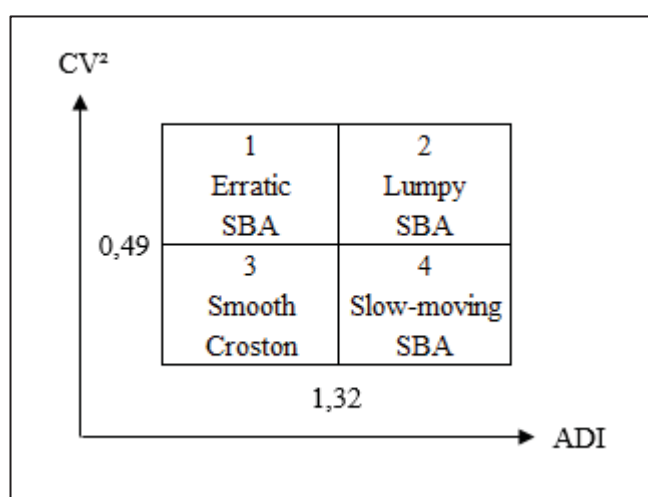
- **“Erratic – ou errática”** – possui alta variabilidade na demanda e baixo nível de intermitência.
- **“Lumpy – ou irregular”** – possui alta variabilidade na demanda e alto nível de intermitência.
- **“Slow-moving – ou intermitente”** – possui baixa variabilidade na demanda e alto nível de intermitência.

A “estrutura” de classificação é similar aos trabalhos previamente publicados, nos quais existem fronteiras estabelecidas entre os diferentes tipos de demanda com valores fixos dividindo as regiões. (ver Figura 5). Entretanto, os autores fornecem evidências teóricas de regiões onde um método de previsão pode ter superioridade universal esperada em relação a outro, de acordo com o tipo de padrão de demanda, assegurando, portanto, que esta classificação possa ser utilizada em outros contextos.

São utilizados três métodos de previsão na análise: Croston, SBA e EWMA (Média Móvel Ponderada Exponencialmente). Segundo os autores, uma linha interessante de pesquisa seria comparar métodos não-paramétricos (Bootstrap) com os métodos paramétricos utilizados. A medida de erro escolhida pelos autores foi o MSE por ser uma medida que permite que resultados teóricos possam ser testados na prática. O resultado foi posteriormente validado em um conjunto de 3.000 séries reais da indústria automotiva.

A classificação proposta por Syntetos e Boylan (2005) é apresenta na Figura 5 abaixo.

FIGURA 5 - CLASSIFICAÇÃO DE SYNTETOS E BOYLAN



FONTE: A autora (2019).

A análise da Figura 5 evidencia que séries do tipo regular (*smooth*) devem ser previstas com o método de Croston, e os demais padrões de demanda com o método SBA. O método EWMA foi constatado como inferior em todas as análises realizadas.

Kostenko and Hyndman (2006) propõem uma pequena modificação no esquema de classificação de Syntetos e Boylan (2005). Segundo os autores, o quadrante três (Figura 5) pode ser dividido diagonalmente em duas regiões, pois em grande parte deste quadrante o método SBA “vence” o método de Croston. Segundo os autores, o método SBA possui uma expectativa teórica de apresentar melhor desempenho em relação ao método de Croston sempre que:

$$CV^2 > 2 - \frac{3}{2} * ADI \quad (28)$$

Esta modificação proposta por Kostenko and Hyndman (2006) foi posteriormente testada e validada por Heinecke, Syntetos, and Wang (2013) através de testes empíricos realizados em 10.000 séries temporais. Os autores fizeram uso das métricas de erro MSE, RGRMSE e MASE, chegando à conclusão que as duas últimas refletem muito melhor as expectativas teóricas acerca dos métodos com melhor desempenho, quando comparadas à primeira. Segundo a opinião dos autores, o tema classificação de demanda com foco em previsão e controle de estoques não tem recebido a atenção suficiente da comunidade acadêmica tanto quanto a relevância do tema necessita. Além disso, sugere que pesquisas futuras busquem avaliar de maneira integrada os métodos de previsão e o impacto gerado no controle de estoques; e também busquem aplicar uma quantidade mais expressiva de métodos de previsão.

O trabalho de Ghobbar (2004) é um dos trabalhos de aplicação mais abrangentes em termos da quantidade de métodos de previsão e métricas de erro utilizadas. No total, foram utilizados treze métodos de previsão, que são em sua grande maioria classificados como técnicas causais (ver Figura 2) – ARRSES, AW, MTBR, Croston, EWMA, DES, MW, SRM, SES, TAES, WCDR, WMA e o WRDF (consultar lista de Siglas para mais detalhes). As sete métricas de erro utilizadas foram o ME, MSE, MAD, RMSE, SSE, MPE e o MAPE. Foram utilizadas 35 componentes da indústria de aviação para estudo. Os resultados evidenciam que ao utilizar mais métricas de erro, as conclusões tornam-se mais difíceis de serem obtidas, pois dependendo da métrica utilizada pode-se chegar a diferentes resultados. O método WCDR foi considerado o melhor método para previsão quadrimestral segundo a maioria das métricas de erro, exceto pelo ME. Na previsão mensal, os métodos WCDR, Croston e WMA obtiveram bons resultados. Na previsão semanal, devido à maior incidência de demandas do tipo “lumpy”, houveram mais divergências nos resultados. O método WMA obteve boa performance de

maneira geral. Embora tendo utilizado diversas métricas de erro, o autor seleciona apenas o MAPE para tecer as conclusões finais de qual método é melhor para cada padrão de demanda.

Em 2008 surge o primeiro trabalho em que são aplicadas técnicas de inteligência artificial para previsão de séries temporais do tipo lumpy. Em seu trabalho, Gutierrez, Solis, and Mukhopadhyay (2008) destacam duas grandes vantagens em utilizar redes neurais: a flexibilidade de adaptação aos diferentes comportamentos de demanda e a capacidade em capturar padrões não-lineares nos dados. Os autores utilizaram a rede neural do tipo *Multi Layer Perceptron* (MLP) em 24 séries do tipo “lumpy” e constatam que o método proposto possui melhor desempenho geral quando comparado aos métodos tradicionais de Croston, SBA e SES. Foram utilizadas três métricas de erro: MAPE, RGRMSE e PB (*Percentage Best*). Os resultados mostram que os métodos tradicionais possuem melhor desempenho apenas quando a quantidade de observações não-nulas aumenta consideravelmente (séries mais próximas do tipo *smooth*). Nestes casos, as técnicas tradicionais foram ajustadas com coeficientes de suavização bem pequenos. (GUTIERREZ, 2008)

A partir de 2008, há um aumento considerável na quantidade de aplicações de técnicas baseadas em inteligência artificial para previsão de séries temporais.³ Porém os trabalhos não endereçam a questão da possível escolha do método de previsão e controle de estoque de acordo com o tipo de padrão de demanda, mas apenas da performance do método aplicado.

Outro trabalho relevante na área foi publicado por Bacchetti and Sacconi (2012), o qual investigou as principais lacunas entre o avanço das pesquisas científicas e as aplicações das técnicas na prática. Segundo os autores, há uma dificuldade em se identificar a existência de um método de previsão que possa ser considerado “o melhor” para itens de reposição (*spare parts*), apesar de novos métodos de previsão estarem surgindo. Os autores elucidam que embora muitos trabalhos tenham evidenciado desempenho superior dos métodos derivados de Croston, ainda não foi realizada uma análise investigativa abrangente, pois além de cada pesquisa utilizar dados diferentes, também são utilizadas métricas de erro distintas, dificultando a análise. Os autores também criticam a falta de preocupação científica com os desafios da aplicabilidade dos métodos em contextos reais, como por exemplo indisponibilidade e/ou dificuldade em obter e tratar os dados, complexidade de utilização dos métodos, habilidades do usuário etc.

O trabalho de Rego e Mesquita (2014) é a primeira contribuição brasileira nesta linha de pesquisa. Os autores realizam uma análise integrada de previsão e controle de estoques em

³ Consulta à plataforma Scopus utilizando a busca avançada retorna um total de 27 documentos publicados desde 2008. (Termo de busca utilizado: TITLE-ABS-KEY ("Forecast" OR "Forecasting" AND "Neural Networks" AND "Time Series") AND REF (Gutierrez 2008))

aproximadamente 10.000 produtos de uma indústria automotiva, fazendo uso dos métodos MMS, SBA e Bootstrap para previsão de demanda, e de seis distribuições diferentes para a demanda ao longo do LTD. Além disso, os autores abordam diferentes unidades temporais (semanal e mensal) e estratégias de análise (SDA – *Single Demand Approach* vs. PDA – *Period Demand Approach*). Os autores utilizam a classificação de Syntetos e Boylan (2005) para fazer recomendações das melhores práticas para cada tipo de padrão de demanda. Os resultados mostram que demandas do tipo *lumpy* devem ser sempre previstas com o Bootstrap e do tipo Erráticas com o SBA, enquanto as demandas do tipo *slow-moving* e *smooth* não possuem um único vencedor definido (variam de acordo com os critérios definidos pelos autores). Vale comentar que uma contribuição interessante dos autores é analisar a periodicidade ideal que os estoques podem ser monitorados - a maioria recai na periodicidade mensal. Todas as análises foram realizadas utilizando o MSE como indicador de desempenho.

No mesmo ano, outro trabalho de grande destaque foi publicado por Kourentzes (2014). O autor utiliza os métodos de Croston, SBA, SES e o TSB e faz uso das métricas de erro MASE, sAPIS e duas novas proposta – o MSR e o MAR, os quais são baseados no conceito de ocorrência de taxas de demanda ao longo do tempo, ao invés de apenas considerar a demanda ocorrida. O trabalho fornece direcionamento para a otimização dos parâmetros cada método, o que contribui para a melhoria da previsão de demanda intermitente. Contudo, o autor revela que não foi possível identificar de forma conclusiva quais métodos são de fato mais eficientes para cada padrão de demanda, fato este que levanta questionamentos em relação à utilidade prática do esquema de classificação utilizado (classificação de Syntetos e Boylan (2005)). Segundo o autor, embora classificar as séries nos padrões *errática*, *lumpy*, *smooth* ou *intermitente* seja benéfico para comunicar suas propriedades, a classificação em si pode não contribuir de fato para a seleção do método de previsão. Além disso, o autor argumenta que criar uma forma genérica de escolher o método de previsão se tornará cada vez mais urgente e necessário com o avanço das pesquisas no tema e principalmente com o surgimento de novos métodos de previsão.

O trabalho mais recente publicado nesta linha de pesquisa é de Cheng, Chiang, and Chen (2016). Neste trabalho, os autores aplicam quatro métodos de previsão (MMS, SES, Croston e ARIMA) em 12 itens de reposição de um hospital seguindo o esquema de classificação de Syntetos e Boylan (2005). Os resultados mostram que o método de Croston e o SES geraram as previsões com melhor acurácia para demandas do tipo *lumpy*, errática e *slow-moving*, enquanto para séries o tipo *smooth* o melhor método foi o MMS. A métrica de erro utilizada de base para os resultados foi uma versão modificada do MAPE.

Levando em consideração todas as críticas, sugestões e resultados dos trabalhos supracitados, foram identificados diversas lacunas que fundamentaram o desenvolvimento desta pesquisa. Os principais aspectos foram:

- A linha de pesquisa que desenvolve esquemas de classificação com o objetivo de facilitar a escolha do método de previsão e do método de controle de estoque não tem recebido tanta atenção da comunidade acadêmica quanto deveria.
- A busca por um esquema de classificação de caráter universal torna-se cada vez mais necessária à medida que novos métodos de previsão e controle de estoque surgem.
- A aplicação de uma maior quantidade de métodos de previsão contribui para uma melhor abrangência na análise.
- A escolha do indicador de desempenho é de fato importante para a construção dos esquemas de classificação e identificação dos vencedores, porém os trabalhos publicados não delineiam este aspecto tanto quanto necessário.

3.3. INDICADORES DE DESEMPENHO (ID)

Os indicadores de desempenho utilizados em previsão de séries temporais possuem o objetivo de mensurar a acurácia dos métodos de previsão implementados e fornecer subsídio para comparação e identificação dos melhores desempenhos.

As séries temporais possuem características naturais que podem dificultar a escolha do indicador de desempenho. São exemplos disso a existência de picos, grandes flutuações dos valores da série, e a quantidade de valores zerados. Alguns indicadores podem inclusive não existir para determinadas observações. O Erro Percentual Absoluto Médio (MAPE), por exemplo, não pode ser definido quando o valor real for igual a zero

Eventualmente, um método de previsão pode gerar alguns valores atípicos excessivamente altos ou baixos, também conhecidos como *outliers*, que podem impactar significativamente o valor do erro de previsão, dependendo da forma como for calculado. (ARMSTRONG & COLLOPY, 1992) Nesse caso, uma estratégia válida é buscar um indicador que descarte os valores atípicos, como por exemplo a Mediana do Erro Percentual Absoluto (MdAPE).

Um outro problema surge ao analisar um conjunto de séries simultaneamente: pode haver uma grande diferença de escala entre os valores de uma série e outra, dificultando assim

a comparação da eficiência de diferentes métodos entre as mesmas. (ARMSTRONG & COLLOPY, 1992). Para evitar esse problema, uma alternativa é utilizar indicadores adimensionais, como por exemplo os indicadores percentuais (MAPE, sMAPE), e os indicadores de comparação (*Percent Better*, RAE, GMRAE).

Devido às muitas opções disponíveis na literatura, não é trivial saber qual se deve utilizar ou até mesmo averiguar se a escolha de diferentes métricas levam à diferentes conclusões. Na escolha do indicador, critérios como a facilidade de interpretação de significado numérico, o custo computacional, a sensibilidade do mesmo e a facilidade em relacioná-lo com a tomada de decisão são importantes de serem considerados.

A escolha depende também do objetivo da métrica: se é realizar a otimização dos parâmetros do método de previsão escolhido, ou se é identificar o melhor método de previsão dentre um conjunto de métodos disponíveis.

Uma pesquisa referencial realizada na plataforma *Scopus*⁴ identificou a existência de dezesseis métricas de erro relacionadas com a medição de erros de previsão. O

Quadro 2 apresenta a equação de cada ID, bem como algumas referências de autores que sugeriram a utilização dos mesmos. Considere que n é a quantidade de observações que se deseja mensurar o erro, Y_i é a demanda real ocorrida no instante i , e \hat{Y}_i é a previsão registrada, e R_i é a previsão registrada para um método de referência (para os métodos relativos RAE, MRAE, GMRAE e MdRAE).

É importante comentar o MAPE foi um dos indicadores mais recomendados (BOWERMAN, 2004), (HANKE, 1995) por muitos anos, porém esta prática se alterou ao longo dos anos. Um dos principais problemas do MAPE reside no fato dele não poder ser definido quando a demanda real for nula, devido ao denominador. Em 1993, Makridakis propõe o sMAPE, versão simétrica do MAPE que é capaz de se adaptar aos valores nulos da série real. Em 2000, Makridakis e Hibon relatam terem utilizado os indicadores MdRAE, sMAPE e sMdAPE na competição “M3-competition”.

Para a leitura do

Quadro 2, considere as seguintes variáveis:

Y_i = demanda real para o período i

\hat{Y}_i = previsão para período i

⁴ Termo de busca utilizado na pesquisa avançada: TITLE-ABS-KEY ("Forecast" OR "Forecasting") AND ("Measures" OR "Metric" OR "Measurement" OR "Technique" OR "Method") AND ("Error" OR "Deviation").

$R_i = \text{previsão pelo método benchmark para o período } i$

QUADRO 2 - INDICADORES DE DESEMPENHO

SIGLA	EQUAÇÃO	REFERÊNCIA QUE RECOMENDOU
ME	$ME = \frac{1}{n} \sum_{i=1}^n (Y_i - \widehat{Y}_i)$	-
MAE	$MAE = \frac{1}{n} \sum_{i=1}^n Y_i - \widehat{Y}_i $	-
MAE:Mean	$MAE: Mean = \frac{\sum_{i=1}^n Y_i - \widehat{Y}_i }{\sum_{i=1}^n Y_i}$	Hoover (2006)
MASE	$MASE = media \{p(t)\} \mid p(t) = \frac{ Y_t - \widehat{Y}_t }{\frac{1}{n-1} \sum_{i=2}^n Y_i - Y_{i-1} }$	Hyndman e Koehler (2006)
MAPE	$MAPE = \frac{1}{n} \sum_{i=1}^n 100 \left \frac{Y_i - \widehat{Y}_i}{Y_i} \right $	Bowerman et. al. (2004), Hanke & Reitsch (1995)
MdAPE	$MdAPE = median \{p(i)\} \mid p(i) = \left \frac{Y_i - \widehat{Y}_i}{Y_i} \right $	Armstrong and Collopy (1992), Fildes (1992)
sMAPE	$sMAPE = \frac{1}{n} \sum_{i=1}^n 100 \frac{ Y_i - \widehat{Y}_i }{ Y_i + \widehat{Y}_i /2}$	Makridakis (1993)
sMdAPE	$sMdAPE = median \{s(i)\} \mid s(i) = \left \frac{Y_i - \widehat{Y}_i}{Y_i + \widehat{Y}_i} \right $	Makridakis & Hibon (2000)
MSE	$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \widehat{Y}_i)^2$	-
RMSE	$RMSE = \sqrt{MSE}$	-
GRMSE	$GRMSE = \left(\prod_{i=1}^n (Y_i - \widehat{Y}_i)^2 \right)^{\frac{1}{(2n)}}$	
RGRMSE	$RGRMSE = \frac{(\prod_{s=1}^k (GRMSE_{A,s})^2)^{1/(2k)}}{(\prod_{s=1}^k (GRMSE_{B,s})^2)^{1/(2k)}}$	Fildes (1992), Syntetos e Boylan (2005)
RAE	$RAE = \sum_{i=1}^n \frac{ Y_i - \widehat{Y}_i }{ Y_i - R_i }$	-
MRAE	$MRAE = \frac{1}{n} \sum_{i=1}^n \frac{ Y_i - \widehat{Y}_i }{ Y_i - R_i }$	-
GMRAE	$GMRAE = \left(\sum_{i=1}^n \frac{ Y_i - \widehat{Y}_i }{ Y_i - R_i } \right)^{\frac{1}{n}}$	Armstrong and Collopy (1992), Fildes (1992)
MdRAE	$MdRAE = median \{p(i)\} \mid p(i) = \frac{ Y_i - \widehat{Y}_i }{ Y_i - R_i }$	Armstrong and Collopy (1992), Makridakis & Hibon (2000)

FONTE: A autora (2019)

Em 1992, Armstrong and Collopy demonstraram que o RMSE era um indicador pouco confiável e, portanto, inapropriado para aferir a acurácia de erros de previsão. Em seu trabalho, Armstrong recomenda a utilização do GMRAE quando o objetivo é calibrar um modelo para um determinado conjunto de séries. Já quando o objetivo é identificar o melhor método de previsão para uma determinada série, o autor recomendou a utilização do MdRAE. Para os casos quando o histórico de dados é demasiadamente curto, recomenda-se a utilização do MdAPE. No mesmo ano, Fildes (1992) também sugere a utilização do MdAPE e do GMRAE.

Em 2006, Hoover propõe uma versão modificada para o Erro Absoluto Médio (MAE:Mean) que consiste na divisão do valor do MAE pela média dos valores reais. O MAE:Mean é um indicador robusto para o tratamento de *outliers*, e ao mesmo tempo fácil de ser interpretado. (BOYLAN & SYNTETOS, 2008)

No trabalho mais recente de Hyndman e Koehler (2006), os autores afirmam que somente um indicador deve ser utilizado quando o objetivo é comparar métodos de previsão para múltiplas séries em conjunto: o Erro Escalonado Absoluto Médio (MASE). As métricas comparadas por Hyndman foram: o MAPE, MdAPE, sMAPE, sMdAPE, MdRAE, GMRAE e MASE. Os autores defendem que todos os demais indicadores possuem falhas, podendo resultar em valores infinitos, indefinidos, ou ainda muito distorcidos. Por isso, propõem que o MASE passe a ser considerado o indicador padrão para este fim.

De maneira geral, é interessante observar que para fins de comparação entre métodos, os mais recomendados são aqueles que calculam a razão entre o erro de um método em relação à um método de referência. O método de referência mais utilizado para erros relativos é o “*random walk*”, mas a média dos últimos períodos também é bastante utilizada. (HYNDMAN & KOEHLER, 2006).

O método do “*Percent Better*” é também bastante utilizado para comparar métodos para múltiplas séries. Este método mede o percentual em que um determinado método de previsão obteve resultado superior ao “*random walk*”. No entanto, ele desconsidera os percentuais de melhoria de cada série. (HYNDMAN & KOEHLER, 2006)

Levando-se em consideração as recomendações da literatura, foram escolhidas três métricas para a identificação dos métodos vencedores neste trabalho, são eles: MAE:Mean, MASE e MSE. Os dois primeiros foram categoricamente recomendados devido à sua robustez e facilidade de interpretação. Optou-se também pela utilização do MSE pois na presença de muitas observações zeradas, o MSE é uma das poucas métricas de erro que conseguem ser aplicadas em todas as séries sem maiores dificuldades.

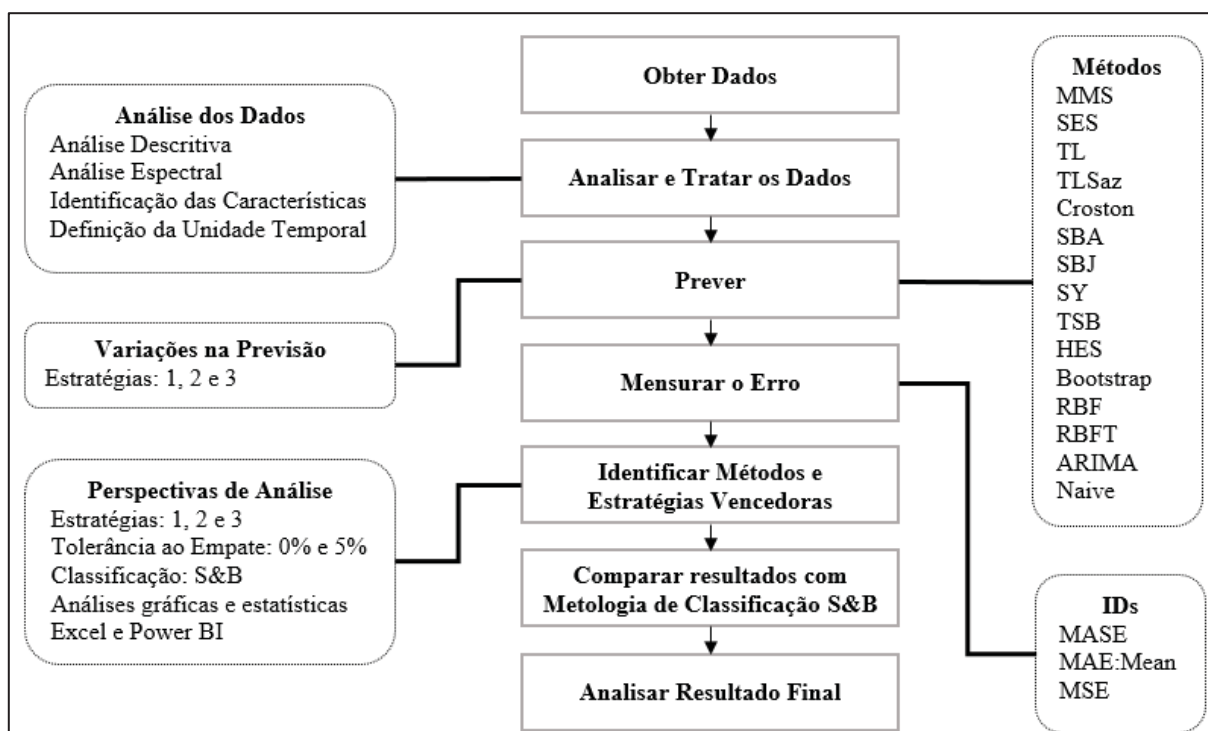
3 METODOLOGIA

Neste capítulo, será apresentada a metodologia científica do trabalho, de forma a detalhar todas as etapas de desenvolvimento e o caminho percorrido do início até a obtenção dos resultados finais.

Um dos trabalhos que serviu de base para a escolha da metodologia deste trabalho foi Kampen, Akkerman, and Pieter (2012), que propôs um *Framework* Conceitual descrevendo as etapas básicas necessárias para estruturação de um esquema de classificação. O principal conceito da metodologia deste trabalho é a premissa de que para avaliar a qualidade da metodologia de classificação de Syntetos e Boylan (2005), foi necessário primeiramente aplicar todos os métodos de previsão e compará-los entre si segundo algum ID, para então comparar os resultados obtidos com os métodos indicados pela mesma.

A Figura 6 apresenta o fluxograma das atividades realizadas. A pesquisa se iniciou com a escolha do setor de interesse e obtenção dos dados. Em seguida, foi realizada uma análise criteriosa dos dados para identificação das principais características presentes, bem como foram empregados alguns tratamentos para mitigar a existência de dados “ruins” para estudo. A linguagem R (software gratuito e livre) foi utilizada para a realização da análise espectral.

FIGURA 6 - FLUXOGRAMA DA METODOLOGIA CIENTÍFICA



FONTE: A autora (2019)

Em seguida, foram aplicados os 15 métodos de previsão supracitados com três estratégias distintas, os quais tiveram seus desempenhos avaliados por três indicadores de desempenho. A linguagem de programação utilizada nestas duas etapas o *Visual Basic for Applications* (VBA) – que é também a interface de programação do *Microsoft Excel*. O computador utilizado para os testes computacionais possui as seguintes configurações: Intel® Core™ i5-4260U CPU @ 140GHz 2.00 GHz com 4,00 GB de memória RAM.

Em seguida, foi realizada a identificação dos métodos e das estratégias vencedoras segundo algumas perceptivas de análise, as quais serão melhor detalhadas mais adiante. Os resultados encontrados foram então comparados com a Classificação de Syntetos e Boylan (2005) e com demais trabalhos levantados na literatura que também aplicaram esta metodologia. A pesquisa se encerrou com a análise dos resultados finais e conclusões percebidas em cima dos resultados obtidos.

3.4. ESTRATÉGIAS DE PREVISÃO

Existem diferentes formas de realizar a previsão durante um horizonte definido de n períodos, que neste trabalho foram denominadas de “Estratégias de Previsão”. Nas estratégias 1 e 2, a previsão é realizada apenas para o próximo instante k (também chamada de previsão “um passo à frente”) sendo repetida n vezes, enquanto na estratégia 3 a previsão é realizada apenas uma vez para todos os n períodos à frente.

Nas estratégias 1 e 2, o *input* de dados e os parâmetros dos métodos de previsão são atualizados a cada passo realizado. Enquanto na estratégia 1, cada nova previsão realizada é inserida no modelo para realização da próxima previsão, na estratégia 2 cada nova demanda real ocorrida é retroalimentada no modelo (supondo-se que a demanda real passa a ser conhecida a cada passo realizado). A quantidade de dados no *input* do modelo se mantém igual, de forma a eliminar o dado mais antigo sempre que é inserido um dado mais recente.

Em síntese:

- (a) Estratégia 1 – prever n vezes um passo à frente, retroalimentando os dados de *input* do modelo com a última previsão.
- (b) Estratégia 2 – prever n vezes um passo à frente, retroalimentando os dados de *input* do modelo com a última demanda real.
- (c) Estratégia 3 – prever 1 vez n períodos à frente.

Nem todas as estratégias são aplicáveis a todos os métodos de previsão. (ver Quadro 3). O método 3, por exemplo, é mais restritivo em termos de aplicabilidade, podendo ser aplicado em apenas 6 métodos de previsão dos 15. Já o método 1, retorna uma previsão de valor constante em determinados métodos.

QUADRO 3 - MÉTODOS VS. ESTRATÉGIAS MATRIZ DE POSSIBILIDADES

MÉTODO	ESTRATÉGIA DE PREVISÃO		
	1	2	3
MMS	Possível	Possível	Impossível
SES	Possível*	Possível	Impossível
TL	Possível	Possível	Possível
TLsaz	Possível	Possível	Possível
Croston	Possível	Possível	Impossível
SBA	Possível	Possível	Impossível
SBJ	Possível	Possível	Impossível
HES	Possível	Possível	Impossível
TSB	Possível*	Possível	Impossível
SY	Possível	Possível	Impossível
Bootstrap	Possível	Possível	Possível
RBF	Possível	Possível	Possível
RBFT	Possível	Possível	Possível
ARIMA	Possível	Possível	Possível
Naive	Possível*	Possível	Impossível

* Possível, porém a previsão será sempre a mesma

FONTE: A autora (2019)

As diferentes estratégias de previsão foram empregadas neste trabalho com o intuito de explorar configurações da previsão que frequentemente são omitidas ou brevemente discutidas nos trabalhos publicados. Além disso, acredita-se que este é um prisma interessante de estudo na área de previsão de séries temporais.

3.5. PERSPECTIVAS DE ANÁLISE

A identificação do melhor método de previsão para uma série temporal pode depender de uma quantidade razoável de atributos e prismas de avaliação. É possível fazer inúmeras combinações de atributos para avaliar a qualidade de previsão dos métodos escolhidos, por exemplo, utilizando múltiplos indicadores de erro e/ou unidades temporais. Porém, à medida que se aumenta a quantidade de atributos, a complexidade de análise também aumenta, podendo


tornar o resultado final pouco conclusivo. Por isso, é importante explorar de maneira estratégica as perspectivas de análise de forma a alcançar a robustez pretendida sem tornar a análise demasiadamente complexa.

De maneira resumida, as perspectivas sob as quais os dados foram analisados neste trabalho foram:

- Unidade Temporal dos Dados: Semanal
- Período de Histórico: 52 semanas
- Período de Previsão: 5 semanas
- Indicadores de Desempenho: MASE, MAE:Mean e MSE
- Estratégias de Previsão: 1, 2 e 3.
- Tolerância ao Erro para definição dos vencedores: 0% e 5%
- Tipo de Série de acordo com a classificação de S&B: *smooth*, *errática*, *slow-moving* e *lumpy*.

Ao avaliar qual o melhor método de previsão segundo algum indicador de desempenho, existe a possibilidade de ocorrer algum empate de valor. Nesse caso, a “vitória” é computada para todos os métodos que empataram. O empate foi definido de acordo com um critério de tolerância percentual, ou seja, se a diferença percentual entre o “melhor método” e os demais for inferior ao limite de tolerância estabelecido, então há ocorrência de empate. Foram analisadas 7 possibilidades de tolerância: 0%, 5%, 10%, 15%, 20%, 25%, 30%. (ver Gráfico 1).

GRÁFICO 1 - QUANTIDADE DE EMPATES VS. TOLERÂNCIA AO EMPATE



FONTE: A autora (2019).

No Gráfico 1, o eixo vertical representa a quantidade de séries nas quais houve empate de 2 ou mais métodos de previsão e no eixo horizontal o percentual de tolerância ao empate. Observa-se que há um grande aumento na quantidade de empates na faixa entre 0% e 5%, que se reduz nas demais faixas. Isso caracteriza uma evidência de que alguns métodos de previsão tiveram performances próximas (mais detalhes no próximo capítulo). Por isso, optou-se por incluir nas perspectivas de análise apenas as tolerâncias de 0% e 5%.

4 DADOS UTILIZADOS

Os dados utilizados neste trabalho foram registros diários de venda de uma loja supermercadista da cidade de Curitiba-PR. O conjunto de dados é formado por um total de 9.339 produtos, e por um histórico de aproximadamente 13 meses (julho/2017 a julho/2018).

Todos os registros de venda encontram-se em “unidades” (por exemplo: lata, pacote, caixa, vidro, garrafa, etc.) mesmo para produtos que possam ser eventualmente vendidos em “packs” ou “pacotes” promocionais. A unidade de tempo de registro dos dados é diária, podendo ser agregada na unidade temporal em que se pretende utilizar na previsão, como por exemplo semanas, meses ou trimestres. Neste trabalho, optou-se por trabalhar na unidade semanal, pois esta oferece nível de detalhe de demanda suficiente para a análise enquanto reduz de forma vantajosa a quantidade de dados a serem processados.

Antes de aplicar modelos de previsão em dados reais, é importante ter uma clara percepção das características presentes nas séries, pois a acurácia dos métodos está diretamente relacionada aos padrões de comportamento das mesmas. Enquanto existem séries de difícil previsibilidade, com alto grau de intermitência e variabilidade na demanda, existem também séries mais “comportadas” e com padrões mais facilmente perceptíveis.

Neste capítulo serão detalhadas todas as análises realizadas nos dados, evidenciando as principais características presentes na demanda e tornando claros os motivos da escolha da unidade temporal de previsão. Serão detalhados também os tratamentos realizados para limpeza dos registros brutos e mitigação de ruído.

4.1. ANÁLISE DESCRITIVA DOS DADOS

A base de dados utilizada possui produtos com os mais variados comportamentos de demanda, e apresenta os quatro padrões de demanda propostos por Syntetos e Boylan (2005). A quantidade de séries de cada tipo varia conforme a unidade temporal utilizada, pois quanto maior é a janela de tempo utilizada (mensal > semanal > diário), mais “suavizados” os dados ficam. De maneira geral, as séries tendem a convergir para o tipo “*smooth*” à medida em que se aumenta a unidade temporal. A mesma série, por exemplo, pode ser “errática” na unidade diária, e ser “*smooth*” na unidade mensal.


Nesse sentido, em termos de previsibilidade e qualidade de previsão, tende a ser mais “fácil” prever uma mesma série na unidade mensal, do que na unidade semanal ou diária devido

à redução da variabilidade do tamanho da demanda, e possivelmente da quantidade de zeros da série.

Por outro lado, deve-se levar em conta o nível de detalhamento desejado para a previsão (se a previsão se destina ao planejamento estratégico, tático ou operacional), pois à medida que se aumenta a unidade temporal, o nível de detalhe da informação reduz.

No Gráfico 2 são apresentadas as proporções dos tipos de série para as unidades temporais diário, semanal e mensal. Pode-se observar que as séries do tipo *slow-moving* predomina no diário (50% do total), seguidas das séries *lumpy* (24%), das *erráticas* (15%) e das *smooth* (11%).

GRÁFICO 2 - TIPOS DE SÉRIE POR UNIDADE TEMPORAL




FONTE: A autora (2019)

Na unidade semanal, a proporção entre os tipos de séries é completamente diferente do diário. As séries do tipo *smooth* tornam-se maioria (51%), seguidas das *slow-moving* (21%), das *erráticas* (19%) e das *lumpy* (9%). Na unidade “Mensal”, as séries *smooth* são majoritárias (73%), seguida desta vez pelas *erráticas* (17%), *slow-moving* (6%) e *lumpy* (4%). A distribuição dos tipos de séries na unidade semanal evidencia que esta unidade é apropriada para ser utilizada na previsão, pois apresenta no geral um bom equilíbrio de comportamento do conjunto de dados.

Outra forma interessante de entender como a unidade temporal transforma o comportamento dos dados é da dispersão dos dados em termos do CV^2 e do ADI (Gráfico 3). À medida que a unidade temporal aumenta, os pontos ficam mais concentrados próximos da origem e dos eixos, caracterizando uma maior homogeneidade nos dados. Em termos de previsibilidade, o “pior cenário de previsão” se caracteriza por uma série com alta intermitência e alta variabilidade na demanda (*lumpy*). Pode-se observar que há uma grande redução na

quantidade das séries *lumpy* entre a unidade diária (24% do total) e semanal (apenas 9% do total).

GRÁFICO 3 - DISPERSÃO CV^2 X ADI DAS SÉRIES POR UNIDADE TEMPORAL



FONTE: A autora (2019)

Outro ponto que impacta consideravelmente a performance de alguns métodos de previsão e dificulta posteriormente o cálculo da acurácia das previsões encontradas é a presença de demanda nulas. Para melhor representar a distribuição da quantidade de zeros existentes nas séries por unidade temporal, foram estabelecidas 10 faixas para a quantidade percentual de zeros em relação ao total de observações, por unidade temporal. (Tabela 1)

Os valores estão apresentados em percentual (%) pois a quantidade de observações é diferente para cada unidade temporal. Há 359 observações para a unidade diária, 52 observações para a unidade semanal e 12 observações para a unidade mensal.

TABELA 1 - DISTRIBUIÇÃO DA QUANTIDADE DE ZEROS POR UNIDADE TEMPORAL

Faixa de Zeros	Diário	Semanal	Mensal
A - 0 a 10%	10,3%	40,5%	63,1%
B - 10 a 20%	7,7%	10,5%	6,3%
C - 20 a 30%	7,7%	8,1%	5,4%
D - 30 a 40%	7,1%	6,8%	4,7%
E - 40 a 50%	7,8%	7,4%	7,7%
F - 50 a 60%	8,0%	5,3%	2,8%
G - 60 a 70%	8,4%	5,1%	2,7%
H - 70 a 80%	10,2%	4,9%	2,7%
I - 80 a 90%	13,3%	5,8%	2,7%
J - 90 a 100%	19,5%	5,6%	2,1%

FONTE: A autora (2019).

Para guiar a interpretação da Tabela 1, considere os exemplos a seguir: 19,5% das séries da unidade diária ($19,5\% * 9.339 \approx 1821$ séries) possuem de 90% a 100% ($90\% * 359 \approx 323$ observações) de demandas nulas de um total de 359 observações. Por outro lado, 10,5% das séries da unidade semanal ($10,5\% * 9.339 \approx 980$ séries) possuem de 10% a 20% ($10\% * 52 \approx 5$ observações) de zeros de um total de 52 observações.

É interessante observar que há uma alteração muito significativa na distribuição de zeros entre as unidades “diário” e “semanal”, e notável entre as unidades “semanal” e “mensal”. Enquanto há praticamente 20% dos dados diários que possuem mais de 90% de zeros, nos dados semanais essa proporção se reduz para 5,6% no semanal e 2,1% no mensal. A faixa A também se alterou significativamente, passando de 10,3% no diário para 40,5% no semanal e 63,1% no mensal.

A escolha da unidade temporal altera consideravelmente as características dos dados a serem utilizados na previsão. Consequentemente, é possível que um determinado método de previsão tenha bom desempenho para uma unidade temporal, porém ruim em outra.

Outra informação relevante para a aplicação de métodos de previsão de séries temporais é a magnitude da demanda no conjunto de dados. Ao medir o erro e comparar métodos de previsão, é importante ter em mente que magnitudes diferentes de demanda geram magnitudes diferentes de erro - dependendo do ID utilizado - e isso deve ser considerado na análise.

TABELA 2 - HISTOGRAMA DO VOLUME DE VENDA

	Classe	Quantidade	% acum.
A	0 -- 2.000	7.903	84,6 %
B	2.000 -- 4.000	679	91,9 %
C	4.000 -- 6.000	301	95,1 %
D	6.000 -- 8.000	129	96,5 %
E	8.000 -- 10.000	70	97,2 %
F	10.000 -- 12.000	62	97,9 %
G	≥ 12.000	195	100,0 %
	Total	9.339	100,00%

FONTE: A autora (2019).

Na Tabela 2 têm-se a distribuição do volume de vendas total do período em sete diferentes classes. A grande maioria dos produtos (84,6% - Classe A) possuem vendas de até 2.000 unidades no ano. Por outro lado, 195 produtos (2,1% do total de produtos) possuem as maiores vendas registradas. Nessa classe, existem produtos que atingiram vendas de mais de

130.000 unidades no período. Ou seja, uma pequena quantidade de produtos pode ser responsável por uma parcela significativa da receita do mercado.

4.2. PROPOSTA DE TRATAMENTO DOS DADOS

A base de dados utilizada neste trabalho, por se tratar de uma base “bruta” de registros, necessitou de alguns tratamentos prévios à aplicação dos métodos de previsão. Foram identificados, por exemplo, produtos aparentemente descontinuados ou que tiveram possível “ruptura” no estoque, devido à queda repentina da demanda e ocorrência sucessiva de “zeros”.

Estas séries prejudicam a análise de performance dos métodos de previsão que é realizada após a aplicação da metodologia proposta. Por isso, é importante identificar as séries “problemáticas”, e retirá-las do conjunto de dados, a fim de garantir a consistência das análises a serem realizadas.

Outra preocupação foi garantir que as séries utilizadas não fossem compostas apenas por ruído branco, mas que tivessem também características sistemáticas claras. Por isso, optou-se por aplicar Análise Espectral nas séries - uma análise estatística para identificar as séries relevantes para o estudo (conforme será detalhado mais adiante).

A seguir, serão apresentados os três critérios aplicados no tratamento dos dados.

4.2.1. Critério 1 – Menos de seis observações não- nulas

Séries com menos de 6 observações não-nulas de um total de 52 observações históricas foram eliminadas. Esta condição foi utilizada pois é o mesmo critério para poder aplicar os métodos RBF - Redes Neurais de Bases Radiais e ARIMA. Ambos os métodos somente podem ser aplicados em determinada série se há pelo menos esta quantidade de informações “válidas”.

4.2.2. Critério 2 – Dezesesseis observações nulas consecutivas

Séries que registraram dezesesseis observações nulas consecutivas (quatro meses) de um total de 52 observações históricas foram eliminadas, independentemente da posição de início ou término da sequência nula. Esta condição tem o intuito de eliminar da base produtos com demanda possivelmente descontinuada, ou com “ruptura” no estoque.

4.2.3. Critério 3 – Análise Espectral para Identificação de Ruído (Periodograma)

A Análise Espectral clássica de séries temporais, também denominada de Análise de Fourier, consiste em uma técnica estatística de decomposição da variabilidade de séries estacionárias no domínio da frequência. (SHUMWAY, 2011). Ao aplicar a Transformada de Fourier em uma determinada série temporal, a mesma é decomposta em inúmeras senóides e cossenóides de diferentes frequências, o que permite identificar as componentes periódicas (ou sistemáticas) da série em questão.

Um dos estimadores do espectro é o Periodograma, proposto por Schuster (1898), o qual permite identificar as periodicidades nas frequências associadas a picos de concentração de energia espectral. (MORETTIN, 2006). Quando se identifica ausência de componentes periódicas, o periodograma apresenta um comportamento típico de ruído branco: a função espectral apresenta valor constante igual a $2\sigma_a^2$ no domínio da frequência de 0 até 0,5 ciclos, onde σ_a é o desvio padrão da série temporal a_t . O ruído branco corresponde a uma distribuição gaussiana de média nula e desvio padrão σ_a^2 , ou seja, $a_t \sim N(0, \sigma_a^2)$. (NETO, 2004)

Se o leitor estiver interessado na definição do estimador de frequência e no cálculo da função espectral, sugerem-se as seguintes referências: Shumway and Stoffer (2011), Neto (2004) e Morettin and Tolo (2006).


Neste trabalho, esta técnica foi aplicada do conjunto de dados através do software R, utilizando o pacote “*tseries*”, cujo objetivo foi eliminar as séries que fossem compostas unicamente por ruído branco. É válido comentar também que o Periodograma é um método bastante útil para avaliação da eficiência dos métodos de previsão, o qual é muitas vezes aplicado nos resíduos de previsão dos métodos de previsão de cunho mais estatístico, como por exemplo o ARIMA.

4.2.4. Dados Tratados

Após aplicar os três critérios de tratamento de dados descritos anteriormente, o conjunto de dados válidos passou de 9.339 séries para um total de 3.517 séries. Os demais dados não foram utilizados nos modelos de previsão deste trabalho e, portanto, foram descartados.

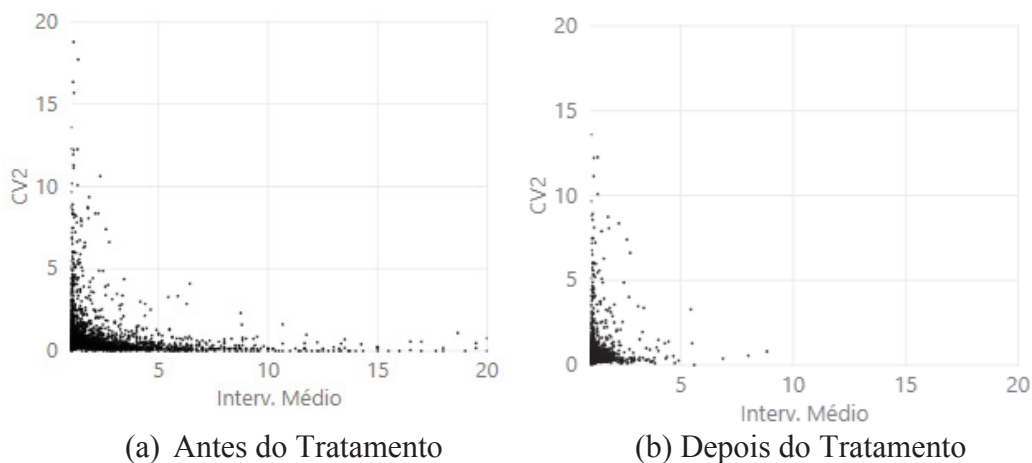
O Diagrama de Venn abaixo (Figura 7) ilustra a quantidade de séries aceitas em cada um dos critérios aplicados. A quantidade de séries aceitas no critério 1 foram 8.709 (93% dos dados), no critério 2 foram 7.206 (77% dos dados) e no critério 3 foram 4.903 (53% dos dados).

FIGURA 7 - DIAGRAMA DE VENN PARA O TRATAMENTO DOS DADOS



FONTE: A autora (2019).


Para ilustrar a dispersão dos dados na unidade semanal em termos do CV^2 e do ADI antes e depois do tratamento realizado, considere o gráfico abaixo. Cada ponto no gráfico representa uma série temporal - no total são 9.339 no gráfico (a) e 3.517 pontos no gráfico (b). Pode-se observar que o tratamento reduz a dispersão dos pontos, concentrando-os mais próximos no intervalo de $0 \leq CV^2 \leq 2$, e $1 \leq ADI \leq 1,5$.

GRÁFICO 4 - CV^2 X ADI DADOS TRATADOS - SEMANAL

FONTE: A autora (2019).

Por fim, apresenta-se a nova distribuição dos tipos de séries segundo a classificação de *Syntetos e Boylan*, após a aplicação dos critérios de tratamento. (Gráfico 5). Das 3.517 séries restantes, 2.253 (64,06%) são do tipo *smooth*, 815 (23,17%) são do tipo *errática*, 252 (7,17%) são do tipo *slow-moving* e 197 (5,6%) são do tipo *lumpy*.

GRÁFICO 5 - TIPOS DE SÉRIE PARA OS DADOS TRATADOS



FONTE: A autora (2019).

Em comparação o Gráfico 2, pode-se observar que a proporção de séries smooth aumentou aproximadamente 14%. As séries erráticas aumentaram 4%, as séries lumpy reduziram 3,5% e as séries slow-moving reduziram 13%.

5 RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados obtidos pela aplicação dos métodos de previsão e medidas de acurácia nas séries temporais de interesse. O capítulo está dividido em três principais seções: análise de desempenho dos métodos; comparação entre as estratégias de previsão; e comparação dos resultados obtidos com os trabalhos correlatos da literatura.

5.1. ANÁLISE DE DESEMPENHO DOS MÉTODOS

Neste capítulo, será realizada uma análise de desempenho dos métodos de previsão através de duas óticas: pela quantidade de vitórias – isto é, a quantidade de séries em que cada método forneceu a melhor previsão em relação aos demais – e pelo erro de previsão. Além disso foi realizada uma análise da quantidade de vitórias em relação à demanda média das séries. Enquanto a quantidade de vitórias proporciona uma visão comparativa entre os métodos, a medida de erro evidencia o desempenho individual de cada técnica.

5.1.1. Quantidade Geral de Vitórias por Método de Previsão

Esta primeira análise tem o intuito de identificar de forma geral quais métodos registraram a maior quantidade de vitórias de acordo com os IDs selecionados. Os resultados estão divididos por estratégia e tolerância ao empate (TE) e encontram-se ordenados pela soma de vitórias registradas nos três IDs. (GRÁFICO 6)

Na estratégia 1, o método TLSaz totalizou mais vitórias com tolerância 0%, sendo ultrapassado pelo método Naive com tolerância 5%. É possível observar que a quantidade de vitórias computadas aumenta bastante (em torno de 50%) com a tolerância de 5%, equilibrando o desempenho entre os métodos. Ou seja, com a tolerância de 5%, é possível perceber que muitos métodos são capazes de “vencer” uma quantidade parecida de vezes.

Na estratégia 2, o método TLSaz totalizou mais vitórias, tanto com tolerância 0% quando 5%. A diferença entre o primeiro e o segundo lugar com TE de 0% é um pouco maior quando comparada com a estratégia 1 (607 vitórias do TLSaz comparadas com 398 vitórias do Naive segundo MAE:Mean). O desempenho dos métodos torna-se bastante similar com a tolerância de 5%.

GRÁFICO 6 - QUANTIDADE GERAL DE VITÓRIAS POR MÉTODO

Estratégia = 1

Método	MAEMean	MASE	MSE	Total	Método	MAEMean	MASE	MSE	Total
TLSaz	554	553	555	1672	Naive	948	703	792	2443
Naive	439	437	670	1546	TLSaz	937	779	648	2364
RBF	443	443	461	1347	SES	1001	627	606	2234
Arima	411	410	442	1263	TSB	989	631	602	2222
MMS	296	290	530	1116	SBJ	947	732	504	2183
SBJ	331	324	284	939	MMS	900	597	649	2146
SBA	318	304	260	882	SBA	937	715	487	2139
TL	280	279	298	857	RBF	896	660	560	2116
SES	213	205	421	839	Arima	899	645	531	2075
TSB	218	213	398	829	Croston	928	609	431	1968
RBFT	266	265	258	789	HES	937	602	425	1964
Croston	204	196	208	608	SY	925	602	425	1952
SY	204	197	204	605	TL	758	520	394	1672
HES	199	189	195	583	RBFT	744	505	353	1602
Bootstrap	27	27	82	136	Bootstrap	32	31	84	147

(a) TE = 0%

(b) TE = 5%

Estratégia = 2

Método	MAEMean	MASE	MSE	Total	Método	MAEMean	MASE	MSE	Total
TLSaz	607	604	647	1858	TLSaz	1013	830	744	2587
Naive	398	395	608	1401	TSB	977	558	633	2168
RBF	399	401	450	1250	SBJ	968	646	478	2092
Arima	378	377	423	1178	RBF	904	604	553	2061
MMS	310	306	540	1156	SBA	943	616	462	2021
TL	311	304	334	949	Naive	793	525	680	1998
SBJ	314	305	272	891	MMS	883	514	648	1995
RBFT	302	295	292	889	Arima	866	585	521	1972
TSB	219	206	447	872	SES	925	477	516	1918
SBA	283	275	231	789	SY	950	525	378	1853
SES	192	186	380	758	Croston	946	525	379	1850
SY	202	188	191	581	TL	810	554	435	1799
Croston	191	181	199	571	HES	917	480	353	1750
HES	170	159	164	493	RBFT	803	546	393	1742
Bootstrap	23	23	85	131	Bootstrap	26	26	87	139

(a) TE = 0%

(b) TE = 5%

Estratégia = 3

Método	MAEMean	MASE	MSE	Total	Método	MAEMean	MASE	MSE	Total
Arima	860	859	1045	2764	Arima	1330	1113	1151	3594
RBF	783	776	883	2442	RBF	1243	1020	998	3261
TLSaz	694	692	669	2055	TLSaz	1142	931	792	2865
Bootstrap	322	322	370	1014	TL	976	693	584	2253
TL	316	305	362	983	RBFT	936	665	553	2154
RBFT	294	288	312	894	Bootstrap	494	407	408	1309

(a) TE = 0%

(b) TE = 5%

FONTE: A autora (2019).

Na estratégia 3, os métodos ARIMA e RBF se destacam perante os demais, em ambos os cenários de tolerância. Mesmo com a tolerância de 5%, o desempenho entre os métodos não se torna tão equilibrada quanto nas estratégias 1 e 2. A quantidade geral de vitórias também foi computada para os demais indicadores de desempenho levantados na fundamentação teórica. (Ver Apêndice A). O resumo dos resultados é apresentado no quadro abaixo.

QUADRO 4 - RESUMO DA QUANTIDADE GERAL DE VITÓRIAS – PRIMEIRO LUGAR POR CATEGORIA

Estratégia	IDs escolhidos		Todos os IDs	
	TE = 0%	TE = 5%	TE = 0%	TE = 5%
1	TLSaz	Naive	Naive	Naive
2	TLSaz	TLSaz	Naive	Naive
3	Arima	Arima	Arima	Arima

FONTE: A autora (2019).

Os resultados gerais mostram que os métodos TLSaz e Naive se destacam perante os demais nas estratégias 1 e 2, e o método ARIMA se destacou de maneira mais sobressalente na estratégia 3. Entretanto, pode-se observar que não há método de previsão que seja totalmente hegemônico perante os demais. Ou seja, todos os métodos são capazes de ser vencedores em algumas séries, seja em maior ou em menor quantidade. Mesmo os métodos que mais registraram vitórias – como por exemplo o ARIMA na estratégia 3 segundo o Erro MSE (1.045 vitórias) – venceram em menos de 30% da quantidade total de séries avaliadas (3.517 séries).


Em termos práticos, isso significa que quando se tem um conjunto de dados que apresenta os mais diversos comportamentos de demanda, a escolha de apenas um método de previsão não é suficiente. Diante deste resultado, surge a necessidade de investigar possíveis características em comum nas vitórias computadas, como por exemplo certos padrões diante dos quais algum método sempre tenha registrado desempenho superior de forma frequente.

5.1.2. Quantidade de Vitórias por Método de Previsão e Tipo de Série


Para analisar com maior profundidade a quantidade de vitórias registradas em cada método de previsão, os resultados foram categorizados segundo os padrões de demandas propostos por Syntetos e Boylan (2005). Nos Gráficos 7, 8 e 9 são apresentados os resultados para as estratégias 1, 2 e 3 respectivamente, segundo o ID MASE e tolerância de 0% de empate.

GRÁFICO 7 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 0%, ESTRATÉGIA = 1)

Classificação de SB ● Errática ● Lumpy ● Slow-Moving ● Smooth



(a) Visualização por Método



(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

As demais variações de análise (IDs = MAE:Mean e MSE e TE = 0% e 5%) foram incluídos no Apêndice B por motivos de espaço.

Na estratégia 1 (GRÁFICO 7), para a série do tipo *smooth*, o método com maior quantidade de vitórias foi o TLSaz, seguido da RBF. As séries do tipo errática foram melhor previstas pela RBF, seguido do Naive. As séries do tipo *slow-moving* e *lumpy* foram melhor previstos pelo método Naive.


Pode-se observar que mesmo com maior nível de detalhe a falta de predominância dos métodos de previsão permanece. Os resultados mostram que todos os métodos de previsão, sem exceção, são capazes de “vencer” em todos os tipos de série. Existe de fato uma ligeira superioridade da quantidade de vitórias de alguns métodos, porém pouco significativa em relação ao total de séries. O método TLSaz, por exemplo, computou 423 vitórias para as séries do tipo *smooth*, o que representa aproximadamente 19,5% do total de séries deste tipo (2.168 séries).

Na estratégia 2 (GRÁFICO 8), o panorama é similar à estratégia 1. O método TLSaz continua se destacando para séries do tipo *smooth*, seguido da RBF. Há praticamente um empate registrado em diversos métodos para as séries do tipo errática, com os métodos Naive e TLSaz nas primeiras colocações. Uma mudança ocorre em relação às séries *lumpy* e *slow-moving*: o método SBJ aparece em primeiro lugar para ambos, porém não é tão predominante perante os demais métodos.


Na estratégia 3 (GRÁFICO 9) os resultados são interessantes. Os métodos ARIMA, RBF e TLSaz possuem bastante destaque. O ARIMA é o que computou mais vitórias para as séries do tipo *smooth*, *lumpy* e errática e segundo lugar para *slow-moving*. A RBF aparece em primeiro para *slow-moving*, em segundo lugar nas séries errática e *lumpy* e em terceiro nas séries do tipo *smooth*. A TLSaz é o segundo colocado nas séries *smooth* e terceiro nas séries *slow-moving* e errática. Para as séries do tipo *smooth*, por exemplo, os três métodos juntos são capazes de ganhar em 1.504 séries, totalizando aproximadamente 70% do total de séries.

É recomendado que o leitor também consulte o Apêndice B para visualizar os resultados obtidos com a utilização dos demais indicadores de desempenho escolhidos (MAE:Mean e MSE) e tolerância ao empate (os resultados foram sintetizados no Quadro 5). Observa-se que o MAE:Mean retorna resultados praticamente idênticos ao MASE, enquanto o MSE apresenta algumas diferenças nas primeiras colocações das séries *lumpy* e *slow-moving* na estratégia 2, e na vitória unânime do ARIMA na estratégia 3.

GRÁFICO 8 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 0%, ESTRATÉGIA = 2)



(a) Visualização por Método




(b) Visualização por Classificação de S&B


FONTE: A autora (2019).

GRÁFICO 9 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 0%, ESTRATÉGIA = 3)

Classificação de SB ● Errática ● Lumpy ● Slow-Moving ● Smooth



(a) Visualização por Método



(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

Entretanto, é possível concluir que o resultado geral se mantém: todos os métodos se demonstram capazes de “vencer” em alguma parcela das séries estudadas, porém nenhum deles foi predominante em termos da quantidade de vitórias, especialmente nas estratégias 1 e 2. O aumento da tolerância de 0% para 5% torna a quantidade de vitórias entre os métodos ainda mais próxima uma das outras.

QUADRO 5 - RESUMO DAS QUANTIDADES DE VITÓRIAS POR TIPO DE SÉRIE

Estratégia 1						
Tipo de Série	MASE		MAE:Mean		MSE	
	TE = 0%	TE = 5%	TE = 0%	TE = 5%	TE = 0%	TE = 5%
Smooth	TLSaz	TLSaz	TLSaz	TLSaz	TLSaz	TLSaz
Slow-moving	Naive	Naive	Naive	Naive	Naive	Naive
Errática	RBF	SBA	RBF	HES	Naive	Naive
Lumpy	Naive	Naive	Naive	Naive	Naive	Naive
Estratégia 2						
Tipo de Série	MASE		MAE:Mean		MSE	
	TE = 0%	TE = 5%	TE = 0%	TE = 5%	TE = 0%	TE = 5%
Smooth	TLSaz	TLSaz	TLSaz	TLSaz	TLSaz	TLSaz
Slow-moving	SBJ	SBJ	SBJ	TL	TSB	TSB
Errática	Naive	SBJ	Naive	SBJ	MMS	MMS
Lumpy	SBJ	SBJ	SBJ	SBJ	Naive	Naive
Estratégia 3						
Tipo de Série	MASE		MAE:Mean		MSE	
	TE = 0%	TE = 5%	TE = 0%	TE = 5%	TE = 0%	TE = 5%
Smooth	Arima	Arima	Arima	Arima	Arima	Arima
Slow-moving	RBF	Arima	RBF	Arima	Arima	Arima
Errática	Arima	Arima	Arima	Arima	Arima	Arima
Lumpy	Arima	Arima	Arima	Arima	Arima	Arima

FONTE: A autora (2019).

A análise das diferentes combinações de indicadores de desempenho e tolerância ao empate levam à conclusão de que, utilizando como base a classificação de S&B, não há preponderância absoluta de nenhum método de previsão para nenhum tipo específico de padrão de demanda, o que naturalmente contradiz a proposta dos autores. Os autores sugerem que as demandas do tipo *smooth* sejam previstas com o método de Croston, e as demandas do tipo *errática*, *lumpy* e *slow-moving* sejam previstas com o método SBA.

Nos resultados encontrados, o método de Croston não foi considerado o melhor por nenhum dos indicadores de desempenho nem estratégias utilizadas. Uma pequena similaridade

foi percebida com o método SBJ, que é um dos mais “próximos” do método SBA, o qual surge como um método bom para as séries do tipo errática, *slow-moving* e *lumpy* na estratégia 2.

Por outro lado, os resultados obtidos na estratégia 3 são interessantes devido à predominância do ARIMA e RBF perante os demais métodos de previsão independentemente do tipo de série. Os resultados sugerem que seja realizado um estudo mais detalhado para evidenciar as diferenças entre as estratégias de previsão.

5.1.1. Quantidade de Vitórias versus Demanda Média

Nesta seção, será apresentado um breve estudo realizado com o intuito de investigar se a quantidade de vitórias pode estar relacionada ao tamanho médio da demanda das séries temporais utilizadas. Considere o Gráfico 10 elaborado para as estratégias 1, 2 e 3. Cada ponto no gráfico representa a quantidade total de vitórias computadas por cada método (soma dos IDs MASE, MAE:Mean e MSE) e a demanda média geral das séries nos quais houve vitória.


Na estratégia 1, com a tolerância ao empate nula é possível observar algumas características interessantes. O método TLSaz, o qual registrou a maior quantidade de vitórias, possui a maior demanda média quando comparado aos demais métodos. O método Naive também conquistou uma grande quantidade de vitórias, porém a demanda média registrada é muito mais baixa do que o método TLSaz. O método *Bootstrap* registrou uma quantidade mínima de vitórias, porém fica evidente que estas vitórias ficaram concentradas em séries com os menores valores de demanda média. Com o aumento da tolerância, há uma tendência clara dos pontos se agruparem, deslocando-se para direita e para cima.

Na estratégia 2, acontece um fenômeno bastante parecido. O método TLSaz continua com destaque, a qual se mantém com o aumento da tolerância. O método Naive não registra tantas vitórias quando comparado com a estratégia 1. O método *Bootstrap* continua sendo o método com pior desempenho, porém suas vitórias se concentram em séries com menor demanda média. O aumento da tolerância ao empate provoca um efeito de agrupamento dos pontos deslocando-os ligeiramente para cima e para a direita.

Na estratégia 3, o método ARIMA é o que possui a maior quantidade de vitórias e também predomina em maiores demandas médias. Pode-se observar que a quantidade de vitórias dos métodos RBF e TLSaz são parecidas (a rede neural é ligeiramente melhor), porém a demanda média da RBF é menor que a demanda média do TLSaz.

GRÁFICO 10 - QUANTIDADE DE VITÓRIAS X DEMANDA MÉDIA

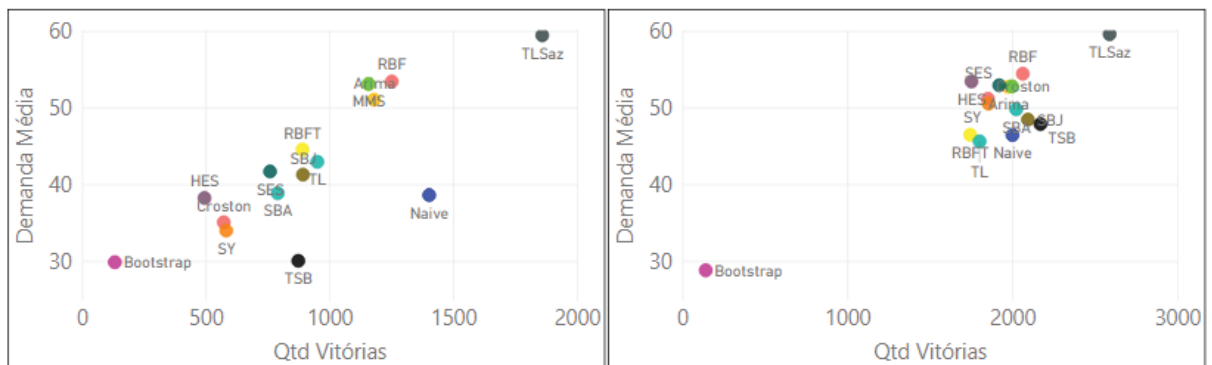
Estratégia = 1



(a) TE = 0%

(b) TE = 5%

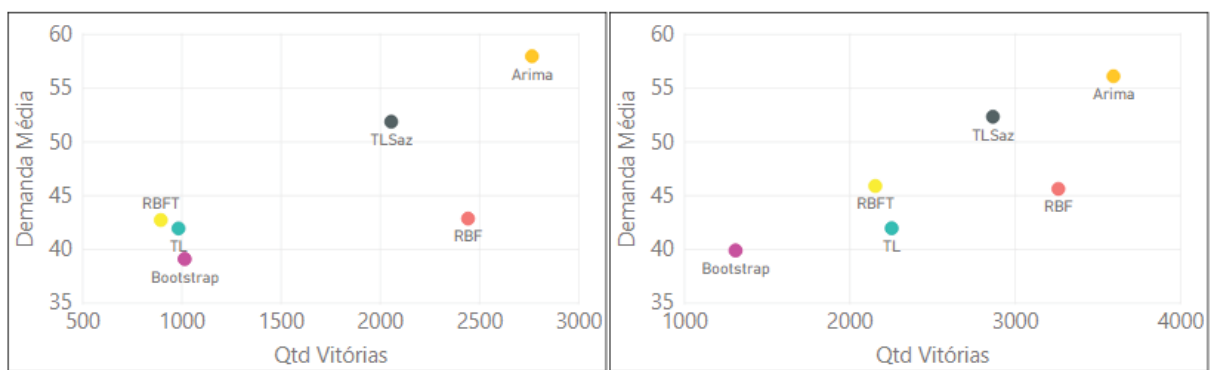
Estratégia = 2



(a) TE = 0%

(b) TE = 5%

Estratégia = 3



(a) TE = 0%

(b) TE = 5%

FONTE: A autora (2019).

Outra vez, o método *Bootstrap* possui a menor quantidade de vitórias registradas, porém as vitórias conquistadas ocorreram em séries com menor demanda média. O efeito de agrupamento dos pontos é mais sutil na estratégia 3, não provocando tanta alteração na posição dos pontos.

Pode-se concluir pela análise dos resultados que o volume da demanda é uma característica que pode contribuir na criação de futuras metodologias de classificação, pois permite distinguir com certa clareza a posição de cada método perante tais características.

5.1.2. Erro de Previsão por Método

Neste capítulo serão discutidos os erros de previsão resultantes de cada método através dos IDs selecionados (MASE, MAE:Mean e RMSE). Conforme previamente detalhado na seção 3.3, vale lembrar que existem diversas maneiras de se calcular o erro. Algumas métricas possuem a desvantagem de gerar valores impossíveis (p.e. divisão por zero) ou grandes distorções na presença de *outliers*. Dessa forma, essas particularidades são importantes e devem ser sempre monitoradas em análises de desempenho quantitativas. Nos gráficos utilizados nesta seção os *outliers* e os valores impossíveis foram ocultados da visualização.

Para representar o erro de previsão registrado em cada método foi escolhido o gráfico *Box Plot*⁵, o qual permite a visualização rápida dos atributos da distribuição do erro de cada método, a saber: primeiro quartil, média, mediana, terceiro quartil e valores mínimo e máximo. (Obs. a média é representada pelo ponto preto). Quanto mais próximo de zero estiverem concentrados os dados, mais preciso o método de previsão. Além disso, uma menor amplitude do gráfico evidencia uma menor variabilidade dos erros, o que demonstra maior consistência do método em realizar as previsões.

Cada estratégia de previsão e tipo de série foram avaliados de maneira independente. Por motivos de espaço, foram incluídos neste capítulo apenas os resultados segundo o MASE para estratégias 1, 2 e 3. Os demais gráficos (segundo os IDs MAE:Mean e RMSE) foram incluídos no Apêndice C e tabelados no Apêndice D.

⁵ Visualização pré-definida sem *outliers* no Power BI. Para maiores informações sobre o *Box Plot*, acesse: <https://www.khanacademy.org/math/ap-statistics/summarizing-quantitative-data-ap/stats-box-whisker-plots/v/judging-outliers-in-a-dataset>

GRÁFICO 11 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 1)



FONTE: A autora (2019)

Na estratégia 1 (Gráfico 11), observa-se que para séries do tipo errática, o SBA e o SBJ possuem leve destaque em relação aos demais devido à menor amplitude de erro e valor mínimo próximo de zero. Para as séries *smooth*, o método TLSaz é o que possui menor valor, porém é também aquele que possui maior amplitude de erro. Além disso a mediana de todos os métodos ficou bastante próxima, com um pequeno destaque para o SES que possui menor amplitude e média perante os demais. Já nas séries do tipo *lumpy*, há uma diferença mais significativa entre os métodos SBA e SBJ perante os demais, os quais apresentaram menor amplitude de erro e concentração dos dados mais próxima de zero. Por fim, as séries *slow-moving* apresentam uma pequena divergência entre os IDs: segundo o MASE todos os métodos foram muito próximos; segundo MAE:Mean, o SBA e SBJ foram levemente melhores; e segundo RMSE, o MMS teve pequeno destaque perante os demais.

Na estratégia 2 (Gráfico 12), pode-se observar que nas séries do tipo errática os métodos SBA e SBJ possuem baixa amplitude de erro e menor média perante os demais. Para as séries *smooth*, o método TLSaz é o que possui menor valor mínimo (assim como na estratégia 1), porém é o que possui maior dispersão de erro. Todos os métodos obtiveram resultados semelhantes, com um leve destaque para os métodos SES e *Naive* pela baixa amplitude de erro. Nas séries do tipo *lumpy*, os métodos SBA e SBJ se mostraram levemente melhores em termos de amplitude e média dos erros, principalmente segundo o MAE:Mean. Por fim, nas séries do tipo *slow-moving* diversos métodos obtiveram resultados muito semelhantes (ARIMA, Croston, SES, SBA, SBJ e TSB). O método Naive foi o de menor amplitude de erro, porém a distribuição dos dados ficou mais afastada do zero. Observa-se um pequeno destaque para o SBJ segundo o MAE:Mean.


Na estratégia 3 (Gráfico 13), as séries do tipo errática possuem melhor previsão pelo método ARIMA. Nas séries do tipo *smooth* os métodos tiveram performances muito semelhantes. É possível identificar uma sutil superioridade do método ARIMA. Nas séries do tipo *lumpy*, destacam-se ligeiramente os métodos TL e RBFT devido à menor amplitude do erro e valor médio. Por fim, nas séries *slow-moving* há uma dificuldade maior em identificar o melhor método devido aos diferentes resultados obtidos nos IDs. Os métodos RBF, ARIMA e TL obtiveram os melhores resultados.

GRÁFICO 12 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 2)



FONTE: A autora (2019)

GRÁFICO 13 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 3)



FONTE: A autora (2019)

De maneira geral, algumas características ficaram evidentes. O método TLSaz é um método que em diversas circunstância teve a capacidade de registrar um valor mínimo de erro mais próximo de zero do que quando comparado aos demais métodos (justificando a quantidade de vitórias computadas na seção anterior). Contudo, ele também registrou as maiores amplitudes de erro, evidenciando que há situações em que este método pode “errar” bastante.

Os métodos SBA e SBJ resultaram em baixas amplitudes em grande parte dos casos, evidenciando sua estabilidade e capacidade de gerar bons resultados para séries do tipo errática, *lumpy* e *slow-moving*. Outro resultado interessante é que os diferentes IDs utilizados geraram interpretações similares na maioria dos casos, com exceção das séries do tipo *slow-moving*. Este tipo de série gerou maior divergência e dificuldade de interpretação.

Por fim, vale comentar que a amplitude dos valores de erro (eixo y dos gráficos) demonstra que as séries do tipo *smooth* e *slow-moving* registraram menores erros de previsão quando comparadas às séries errática e *lumpy*. Este resultado sugere que os erros de previsão podem estar mais relacionados à variabilidade da demanda do que à intermitência da série.

5.2. ANÁLISE COMPARATIVA DAS ESTRATÉGIAS DE PREVISÃO

Nesta seção será realizada uma análise de desempenho comparativa entre as estratégias de previsão utilizadas com o intuito de verificar qual delas resultou em menores erros de previsão. Além disso será realizada uma análise mais detalhada entre as estratégias 1 e 3.

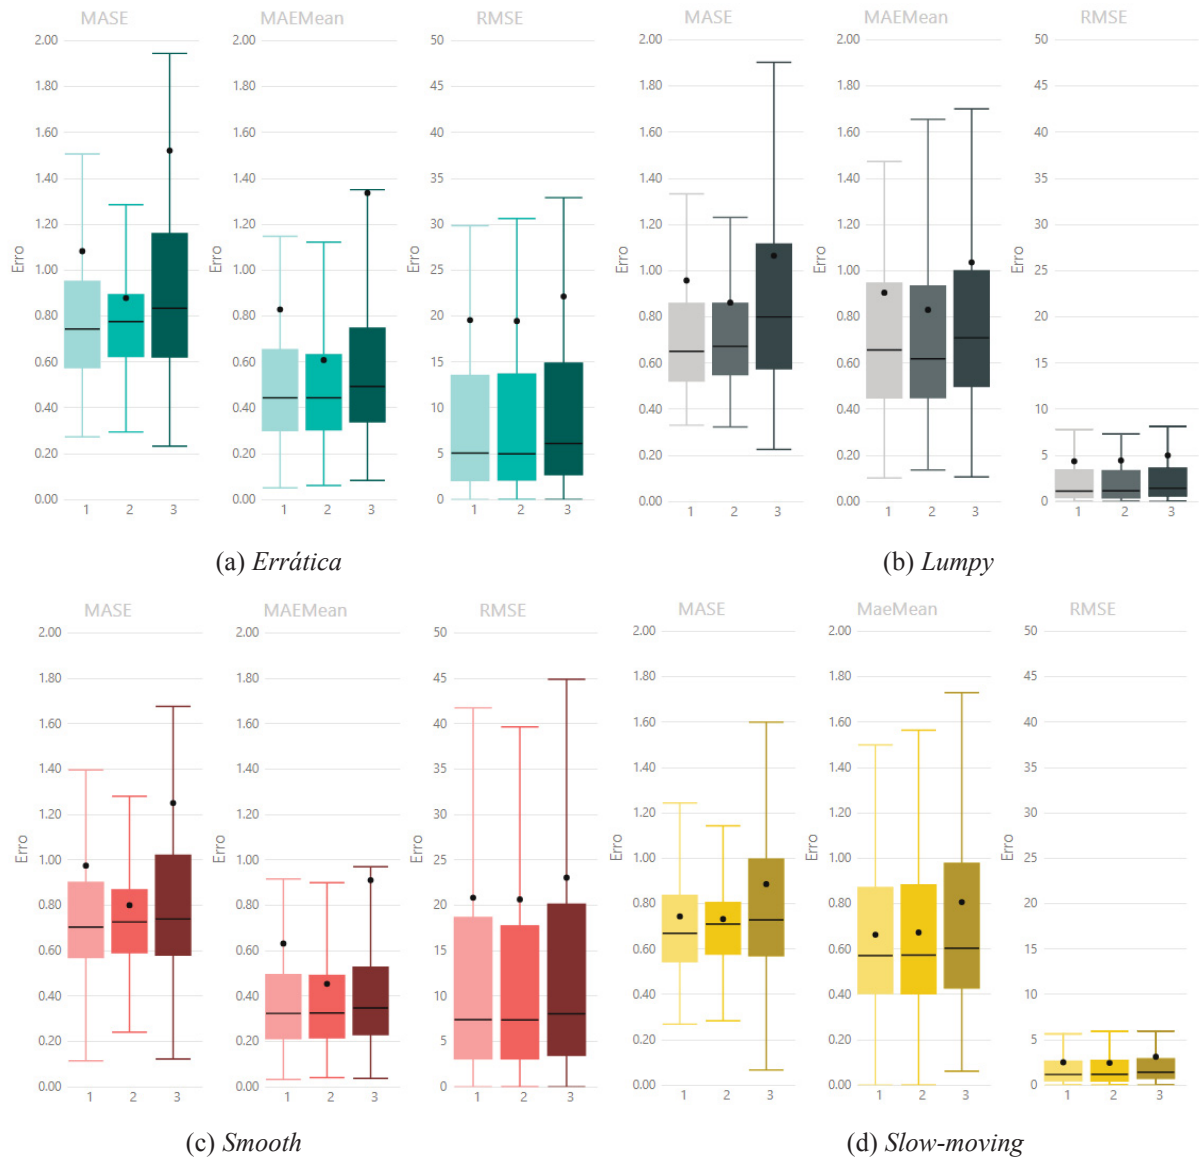
5.2.1. Análise do Erro entre as Estratégias 1, 2 e 3

No intuito de comparar as diferentes estratégias utilizados ao longo deste trabalho foi escolhido o gráfico *Box Plot* (o mesmo utilizado nas seções anteriores), o qual permite uma rápida visualização da distribuição dos erros incorridos no processo de previsão. De maneira semelhante aos demais gráficos utilizados, é válido ressaltar que os *outliers* são retirados da visualização, porém influenciam na posição nos limites inferiores e superiores, bem como na posição da média (representada pelo ponto preto). Logo, se os valores da média e da mediana são muito distantes uma da outra, existem *outliers* que elevam a posição da média.

Os dados foram agrupados de acordo com a classificação de Syntetos e Boylan (2005) e foram utilizados os três IDs escolhidos (o MSE foi substituído pelo RMSE para melhor visualização dos gráficos dos valores máximos). Os resultados foram construídos considerando-

se apenas o menor erro registrado em cada estratégia, independentemente do método de previsão utilizado. Considere o Gráfico 14 abaixo.

GRÁFICO 14 - COMPARAÇÃO DO ERRO POR ESTRATÉGIA, ID E TIPO DE SÉRIE



FONTE: A autora (2019).

De forma intuitiva, é esperado que a estratégia 2, por utilizar valores reais que retroalimentam o modelo durante o horizonte de previsão, produza os menores erros. Portanto, a estratégia 2 não deve ser diretamente comparada às estratégias 1 e 3 devido à condição vantajosa de se “revelar” a demanda ocorrida a cada passo da previsão. Já as estratégias 1 e 3 podem ser consideradas semelhantes em termos de condições de previsão. Enquanto a estratégia 3 realiza a previsão de todo o horizonte somente uma vez, a estratégia 1 realiza a previsão

diversas vezes utilizando os últimos resultados para retroalimentar o modelo. (Para mais detalhes consultar a seção 3.4).

É possível observar que as expectativas se confirmam em relação à estratégia 2: é a que possui menor amplitude de erro e menor valor médio na maioria das configurações. As estratégias 1 e 2 são muito similares segundo o RMSE em todos os tipos de série, o que não ocorre com os demais indicadores de desempenho. Ao comparar as estratégias 1 e 3, é muito evidente que a estratégia 1 resultou em menor amplitude de erro, valor médio e mediana. A estratégia 3 possui amplitude de erro visivelmente maior segundo o MASE, e levemente maior segundo o MAE:Mean e o RMSE.

Dessa maneira, os resultados mostram que a estratégia 1 é mais eficiente que a estratégia 3 pois resulta em menores erros de previsão. Em termos computacionais, a estratégia 1 é aproximadamente três vezes mais custosa que a estratégia 3, o que pode se tornar um fator limitante em aplicações reais, quando se tem uma quantidade grande e produtos que são controlados simultaneamente.

Na Tabela 3 são apresentados os tempos médios em segundos por série temporal, divididos por método de previsão e estratégia.

TABELA 3 – MÉDIA DOS TEMPOS COMPUTACIONAIS (SEGUNDOS)

Método de Previsão	Estratégia 1	Estratégia 2	Estratégia 3
MMS	0,00	0,00	0,00
SES	0,00	0,00	0,00
TL	0,00	0,00	0,00
TLSaz	0,00	0,00	0,00
Croston	0,02	0,02	0,00
SBA	0,02	0,02	0,00
SBJ	0,02	0,02	0,00
HES	0,02	0,01	0,00
TSB	0,01	0,01	0,00
SY	0,02	0,01	0,00
BTS	0,00	0,00	0,00
RBF	0,12	0,11	0,04
RBFT	0,11	0,11	0,04
ARIMA	7,24	6,99	2,51
Naive	0,00	0,00	0,00
Total	7,60	7,32	2,60

FONTE: A autora (2019).

A maioria dos métodos de previsão possui um tempo ínfimo para ser aplicado, exceto pelo método ARIMA. Enquanto na estratégia 1 leva em média 7,6 segundos para aplicar todos os métodos de previsão em uma série qualquer (sendo que 95% deste tempo é devido ao ARIMA), na estratégia 3 leva em média 2,6 segundos (96% também dedicado ao ARIMA).

O tempo computacional total para rodar todas as 3.517 séries para os 15 métodos de previsão foi de 7h25min para a estratégia 1, 7h8min para a estratégia 2 e 2h31min para a estratégia 3.

5.2.2. Comparação Detalhada entre as Estratégias 1 e 3

Nesta seção, será realizada uma análise comparativa mais detalhada em relação às estratégias 1 e 3. A ideia principal é a suposição de que não queremos impor a escolha da estratégia, mas sim investigar qual a melhor combinação de estratégia e método de previsão, isto é, aquela que resulta em menor erro de previsão.

Os resultados da seção anterior mostram que de forma geral, é esperado que algum método de previsão aplicado com a estratégia 1 forneça melhores resultados do que algum método pela estratégia 3. Contudo, sabe-se que isso não é uma garantia, e não ocorre na totalidade dos casos. Por isso, deseja-se verificar se há algum padrão de comportamento nos dados.

Considere as Tabela 4, 5 e 6 nas quais é contabilizada a quantidade de vezes que a estratégia 1 vence a 3 ou vice-versa, quando há empate e quando a métrica não pode ser calculada (p.e. divisão por zero).

TABELA 4 - COMPARAÇÃO DAS ESTRATÉGIAS 1 E 3 - MASE

Tipo de Série	Estratégia 1 vence	Estratégia 3 vence	Empate	Impossível	Total
Errática	454	266	13	82	815
Lumpy	106	55	3	33	197
Slow-Moving	126	62	7	57	252
Smooth	1304	736	27	186	2253
Total	1990	1119	50	358	3517
%	57%	32%	1%	10%	100%

FONTE: A autora (2019).

Segundo o MASE (Tabela 4), a estratégia 1 vence 57% das vezes, enquanto a estratégia 3 vence 32%. Em 1% dos casos ocorre empate entre as estratégias, e em 10% dos casos a métrica não pode ser calculada. Os resultados segundo o MAE:Mean (Tabela 5) são praticamente idênticos ao MASE. Já o MSE (Tabela 6) não possui restrições de cálculo, computando 62% de vitórias para a estratégia 1, 34% de vitórias para a estratégia 3 e 4% de empate.

TABELA 5 - COMPARAÇÃO DAS ESTRATÉGIAS 1 E 3 - MAE:MEAN

Tipo de Série	Estratégia 1 vence	Estratégia 3 vence	Empate	Impossível	Total
Errática	454	263	16	82	815
Lumpy	107	55	3	32	197
Slow-Moving	127	61	8	56	252
Smooth	1292	729	46	186	2253
Total	1980	1108	73	356	3517
%	56%	32%	2%	10%	100%

FONTE: A autora (2019).

É possível concluir, portanto, que de fato a estratégia 1 é mais eficiente do que a estratégia 3 em aproximadamente 60% dos casos e enquanto a estratégia 3 pode de fato ser melhor em aproximadamente 32% dos casos. Essa proporção praticamente se mantém a mesma para os diferentes tipos de série. Logo, não há nenhum padrão específico de demanda em que uma estratégia sempre prevaleça perante outra.

TABELA 6 – COMPARAÇÃO DAS ESTRATÉGIAS 1 E 3 - MSE

Tipo de Série	Estratégia 1 vence	Estratégia 3 vence	Empate	Impossível	Total
Errática	515	271	29	0	815
Lumpy	122	56	19	0	197
Slow-Moving	157	69	26	0	252
Smooth	1381	793	79	0	2253
Total	2175	1189	153	0	3517
%	62%	34%	4%	0%	100%

FONTE: A autora (2019).

Outro prisma interessante de análise é identificar quais métodos de previsão estão associados às vitórias de cada estratégia. Para esta análise, os melhores métodos de cada estratégia foram comparados entre si de acordo com o mesmo indicador de desempenho (MASE, MAE:Mean e MSE). Por motivos de espaço, nesta seção será apresentada a análise apenas segundo o MSE, pois é o método que não possui nenhuma restrição de cálculo. Os resultados para os demais indicadores encontram-se no Apêndice E, caso o leitor deseje consultá-los. Considere as Tabelas 7, 8 e 9 a seguir.

A Tabela 7 apresenta a quantidade de vitórias que cada método de previsão pela estratégia 1 (linhas) vence cada método da estratégia 3 (colunas). Por exemplo, dadas as mesmas séries temporais, utilizar o Naive pela estratégia 1 foi melhor que utilizar o método ARIMA pela estratégia 3 por 198 vezes e melhor que o método RBF 122 vezes. Vale lembrar que é possível que o melhor método de ambas as estratégias seja o mesmo. Por exemplo, utilizar o método TLSaz com a estratégia 1 foi melhor que utilizar o mesmo método pela estratégia 3 195 vezes. A RBF aplicada com a estratégia 1 foi considerada melhor quando comparada à estratégia 3 por 136 vezes. Pode-se observar que os métodos ARIMA e RBF, por terem sido os métodos mais eficazes na estratégia 3, acabam contabilizando as maiores quantidades de “derrota”.

TABELA 7 - QUANTIDADE DE VITÓRIAS POR MÉTODO – MSE ESTRATÉGIA 1 VENCE A 3

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	43	21	17	68	30	152	331
SES	31	12	11	67	21	109	251
TL	63	1	0	4	23	2	93
TLSaz	11	195	4	11	11	21	253
Croston	19	16	6	43	10	54	148
SBA	18	33	11	61	15	75	213
SBJ	21	32	11	63	15	80	222
HES	15	17	7	43	9	44	135
TSB	19	18	13	67	15	103	235
SY	21	17	10	45	10	48	151
Bootstrap	4	8	1	9	4	2	28
RBF	15	14	17	136	16	56	254
RBFT	63	1	0	4	21	2	91
ARIMA	14	28	12	77	13	143	287
Naive	49	26	18	122	33	198	446
Total	406	439	138	820	246	1089	3138

FONTE: A autora (2019).

Considere a Tabela 8, que é análise oposta da anterior – a quantidade de vezes em que a estratégia 3 (colunas) é melhor que a estratégia 1 (linhas).

TABELA 8 - QUANTIDADE DE VITÓRIAS POR MÉTODO – MSE ESTRATÉGIA 3 VENCE A 1

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	4	11	17	17	4	22	75
SES	0	4	13	15	2	26	60
TL	54	12	29	16	48	8	167
TLSaz	0	227	33	13	17	21	311
Croston	1	9	14	12	1	24	61
SBA	0	10	13	13	4	9	49
SBJ	1	8	11	13	2	13	48
HES	2	4	17	7	4	25	59
TSB	1	4	12	23	2	22	64
SY	2	8	13	9	1	20	53
Bootstrap	0	1	0	1	0	0	2
RBF	4	10	35	118	11	27	205
RBFT	54	12	29	16	48	8	167
ARIMA	0	6	30	28	10	72	146
Naive	3	3	18	17	7	25	73
Total	126	329	284	318	161	322	1540

FONTE: A autora (2019).

É interessante observar que a quantidade total de vitórias dos métodos TLSaz, RBF e ARIMA foram similares, e o maior valor em cada um deles corresponde justamente aos casos que há comparação do método consigo próprio. Por exemplo, o método TLSaz é melhor pela estratégia 3 do que pela 1 por 227 vezes. Outro resultado que chama a atenção são as vitórias computadas pelo método *Bootstrap*, o qual teve um dos piores desempenhos em termos de performance nas análises anteriores, ainda foi capaz de vencer 284 vezes quando aplicado pela estratégia 3, e só não ganhou de si mesmo na estratégia 1.

Por fim, considere a Tabela 9, a qual apresenta a quantidade de empates registrados entre ambas as estratégias. Os métodos com maiores quantidades de empate foram o Bootstrap e o ARIMA pela estratégia 3, e os métodos Naive e MMS pela estratégia 1. É interessante notar que o método TLSaz é um dos métodos com menor quantidade de empate, tanto pela estratégia 1 quanto pela estratégia 3. É possível observar também que os métodos mais simples e tradicionais utilizados na estratégia 1 (p.e. MMS, SES, TL e Naive) foram os que obtiveram as maiores quantidades de empate com os demais métodos na estratégia 3, em especial os métodos mais robustos (p.e. RBF, RBFT e ARIMA).

TABELA 9 - QUANTIDADE DE EMPATES POR MÉTODO – MSE

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	28	0	58	32	28	64	210
SES	29	0	46	29	30	59	193
TL	38	0	5	10	38	19	110
TLSaz	0	1	0	0	0	0	1
Croston	0	0	0	0	0	0	0
SBA	0	0	0	1	0	0	1
SBJ	7	0	4	3	8	4	26
HES	0	0	0	1	0	0	1
TSB	19	0	59	21	20	44	163
SY	0	0	0	0	0	0	0
Bootstrap	3	0	52	16	3	18	92
RBF	0	0	2	1	0	1	4
RBFT	0	0	0	0	0	0	0
ARIMA	2	0	3	3	2	9	19
Naive	36	0	68	39	37	78	258
Total	162	1	297	156	166	296	1078

FONTE: A autora (2019).

A análise das três últimas tabelas evidencia que não parece haver um padrão definido para os métodos que mais vencem em cada estratégia. Como o método ARIMA e o RBF foram os métodos com a maior quantidade de vitórias pela estratégia 1, consequentemente são os métodos em que há a maior quantidade de “derrotas” computadas na Tabela 7, haja vista que é esperado que em 60% a estratégia 1 seja melhor que a estratégia 3.

5.3. COMPARAÇÃO DOS RESULTADOS COM OS TRABALHOS CORRELATOS

Nesta seção, os resultados encontrados ao longo deste trabalho serão discutidos e comparados com os resultados encontrados nos trabalhos correlatos levantados na fundamentação teórica.

Considere o Quadro 6, no qual é apresentado um resumo dos resultados encontrados por trabalhos similares a este na literatura. Para cada tipo de padrão de demanda, foi indicado um ou mais métodos de previsão que apresentaram maior acurácia. Além do trabalho de Syntetos e Boylan (2005), que cria e dissemina a metodologia de classificação, outros quatro trabalhos utilizam como base tal técnica para validar empiricamente ou simplesmente comparar seus resultados e identificar os métodos que obtiverem melhor desempenho em cada um dos padrões definidos de demanda.

É possível observar que há uma grande divergência entre os resultados dos trabalhos no que tange a escolha do método de previsão. Diante de tais circunstâncias, algumas hipóteses podem ser levantadas em relação a este cenário: a metodologia de classificação proposta por Syntetos e Boylan (2005) pode não ser universal como se relata; a utilização de diferentes dados em cada trabalho pode gerar impacto no resultado; e a falta de uniformidade na escolha dos indicadores de desempenho pode de fato contribuir para esta diferença. Logo, todos estes fatores combinados contribuem para que seja difícil comparar os resultados entre os trabalhos levantados, e também compará-los com o resultado encontrado neste trabalho.

QUADRO 6 - RESUMO DOS RESULTADOS DE TRABALHOS CORRELATOS NA LITERATURA

Trabalhos Correlatos	Tipos de Padrão de Demanda				IDs utilizados
	Smooth	Slow-moving	Errática	Lumpy	
Syntetos e Boylan (2005)	Croston	SBA	SBA	SBA	MSE
Gutierrez, Solis, and Mukhopadhyay (2008)	Tradicionais	Redes Neurais	Redes Neurais	Redes Neurais	MAPE, RGRMSE e PB
Rego e Mesquita (2014)	Varia	Varia	SBA	Bootstrap	MSE
Kourentzes (2014)	Varia	Varia	Varia	Varia	MASE, sAPIS, MSR e MAR
Cheng, Chiang e Chen (2016)	MMS	Croston e SES	Croston e SES	Croston e SES	MAPE

FONTE: A autora (2019).

Considere o Quadro 7, que apresenta os resultados encontrados neste trabalho em relação aos métodos que registraram a maior quantidade de vitórias para cada uma das estratégias utilizadas. Conforme discutido nas seções anteriores, alguns métodos se destacaram perante os demais em determinadas categorias, embora com pouca representatividade percentual em relação ao total de séries utilizadas na análise.

O método TLSaz foi o que registrou maior quantidade de vitórias para demandas do tipo *smooth* nas estratégias 1 e 2. O método *naive* teve bons resultados no geral para a estratégia 1, o SBJ para a estratégia 2. O método ARIMA obteve grande destaque para todos os tipos de série na estratégia 3. Apenas a demanda do tipo errática gerou resultados muito distintos para as métricas utilizadas, inviabilizando a escolha de algum método.

QUADRO 7 - RESUMO DOS RESULTADOS ENCONTRADOS PARA A QUANTIDADE DE VITÓRIAS

Estratégias	Tipos de Padrão de Demanda				IDs utilizados
	Smooth	Slow-moving	Errática	Lumpy	
1	RLSaz	Naive	Varia	Naive	MASE MSE MAE:Mean
2	RLSaz	SBJ ou TSB	Varia	SBJ	MASE MSE MAE:Mean
3	Arima	RBF ou Arima	Arima	Arima	MASE MSE MAE:Mean

FONTE: A autora (2019).

É possível concluir, portanto, que os resultados encontrados neste trabalho são diferentes dos resultados encontrados em trabalhos similares na literatura. O trabalho que mais se assemelha é o de Kourentzes (2014), o qual não encontrou nenhum método completamente hegemônico em nenhum dos padrões de demanda. O autor relata que não foi possível identificar de forma conclusiva quais métodos são de fato mais eficientes para cada padrão de demanda, fato este que levanta questionamentos em relação à utilidade prática do esquema de classificação utilizado (classificação de Syntetos e Boylan (2005)). Segundo o autor, embora classificar as séries nos padrões errática, *lumpy*, *smooth* ou intermitente seja benéfico para comunicar suas propriedades, a classificação em si pode não contribuir de fato para a seleção do método de previsão.

5.4. DISCUSSÃO DOS RESULTADOS

Nesta seção serão discutidos os principais resultados apresentados neste capítulo. Conforme previamente exposto, os resultados da previsão foram analisados de diferentes perspectivas, gerando diversos cenários de análise: indicadores de desempenho MASE, MAE:Mean e MSE; tolerância ao empate de 0% e 5%; estratégias de previsão 1, 2 e 3; e os tipos de padrão de demanda *smooth*, *slow-moving*, errática e *lumpy*.

A análise geral de comparação entre os métodos em termos da quantidade de vitórias evidencia que as vitórias são relativamente bem niveladas entre os mesmos, não havendo nenhum método claramente preponderante perante os demais. As vitórias individuais dos métodos representaram no máximo 30% da quantidade total de séries no melhor dos cenários. Em termos práticos, isso significa que quando se tem um conjunto de dados diverso e que

apresenta os mais diversos comportamentos de demanda, a escolha de apenas um método de previsão é insuficiente.

A análise da quantidade de vitórias dos métodos segregada por tipo de série mostrou que todos os métodos possuem potencial de vencer em qualquer tipo de série, em maior ou em menor quantidade. Esse resultado “quebra” de certa forma o mito de que os métodos derivados de Croston, por exemplo, possam ser utilizados somente em séries intermitentes, já que foram elaborados em sua concepção para tal finalidade. Todos os métodos podem, e devem ser utilizados sem quaisquer restrições relacionadas ao tipo de demanda. Por outro lado, outro mito que pode ser considerado “quebrado” é o de que o método ARIMA não possui bom desempenho em séries intermitentes. Na realidade, o ARIMA se revelou como um bom método para ser usado em qualquer tipo de série na estratégia 3.

Em termos da quantidade de vitórias conquistadas por cada método, o método TLSaz se destacou para as séries do tipo *smooth* nas estratégias 1 e 2. O método Naive se sobressaiu para as séries do tipo *slow-moving* e *lumpy* na estratégia 1, e o método SBJ obteve bons resultados nas séries *lumpy* e *slow-moving* na estratégia 2. A estratégia 3 apresentou resultados mais contundentes, nos quais o ARIMA predomina na grande maioria dos cenários,

A análise dos erros de previsão incorridos em cada método gerou resultados interessantes: alguns métodos possuem distribuição de erro notavelmente mais estáveis que outros. Por exemplo, os métodos SBA e SBJ apresentaram baixas amplitudes de erro em grande parte dos cenários, evidenciando sua estabilidade e capacidade de gerar bons resultados para séries do tipo errática, *lumpy* e *slow-moving*. Isso significa que embora estes métodos não tiveram destaque em relação à quantidade de vitórias, eles são vantajosos em termos de consistência de resultado.

Por outro lado, o método TLSaz chama bastante a atenção, pois ao mesmo tempo que obteve destaque na quantidade de vitórias para as séries do tipo *smooth* nas estratégias 1 e 2, registrou também as maiores amplitudes de erro. Isso evidencia que o método é capaz de se destacar por contemplar a sazonalidade, porém pode errar demasiadamente nas séries que não apresentam tal característica.

Já na estratégia 3, o método ARIMA se consagra melhor em termos de desempenho, tanto pelo critério de quantidade de vitórias quanto pelo critério de estabilidade de erro, seguido do método RBF e TLSaz. Juntos, estes métodos conseguem obter os melhores resultados em aproximadamente 70% das séries utilizadas.

Foi realizada uma análise comparativa entre as estratégias de previsão utilizadas, no intuito de verificar qual delas é capaz de produzir os menores erros de previsão. Os resultados

mostram que a estratégia 2 é a que registrou menor amplitude geral nos erros de previsão, seguido da estratégia 1 e depois da estratégia 3. De fato, intuitivamente era esperado que o erro de previsão fosse menor na estratégia 2 devido à característica de retroalimentação do modelo com os dados reais à cada passo da previsão realizada.

Entre as estratégias 1 e 3, verificou-se que em cerca de 60% das séries é melhor utilizar a estratégia 1, pois ela tem menor erro de previsão esperado, embora seja computacionalmente mais “cara”. Em termos práticos, pode se tornar inviável utilizar a estratégia 1, principalmente devido ao método ARIMA.

Diante de todos os resultados, constata-se que a metodologia de Syntetos e Boylan de fato já está um tanto desatualizada devido à grande quantidade de métodos de previsão que surgiram desde o ano de sua publicação. Com o aumento da quantidade de técnicas, ficou mais difícil criar um método de classificação capaz de se encaixar de maneira universal em todos os contextos onde for aplicada. Por isso, o desafio de criar uma metodologia de classificação única e universal ainda é enorme.

6 CONSIDERAÇÕES FINAIS

Neste trabalho foi conduzido um estudo aplicado em dados reais do setor supermercadista cujo foco foi testar e investigar a eficiência da metodologia de classificação de padrão de demanda proposta por Syntetos e Boylan (2005). Esta metodologia fornece direcionamento na escolha do método de previsão a ser utilizado de acordo com algumas características inerentes das séries temporais. Para a realização do estudo, foi utilizada uma vasta gama de métodos de previsão e indicadores de desempenho.

O levantamento do referencial teórico deixou evidente alguns pontos importantes. Em primeiro lugar, diversos autores relatam que embora este tema seja de extrema utilidade e relevância para aplicação em contextos reais, essa linha de pesquisa não tem recebido atenção da comunidade científica tanto quanto necessita. Além disso, a busca por uma metodologia de classificação de caráter universal não tem acompanhado a velocidade de criação de novos métodos de previsão e reposição de estoques.

Este trabalho contribui com a literatura ao se propor a cobrir algumas lacunas existentes na área, principalmente ao fazer uso de uma quantidade mais compreensiva e atualizada de métodos de previsão, e ao considerar a importância de utilização e comparação entre múltiplos indicadores de desempenho. Além disso, foram elaboradas três abordagens de previsão, denominadas de “Estratégias de Previsão” visando explorar este aspecto pouco abordado em trabalhos de previsão de séries temporais.

Os resultados da previsão foram analisados de forma extensiva, de forma a proporcionar ao leitor diversas perspectivas de análise e um vasto material de consulta que pode ser utilizado como *benchmarking* para pesquisas futuras.

A análise dos resultados deixou evidente que embora a classificação proposta por Syntetos e Boylan seja importante para comunicar as principais propriedades das séries temporais, ela não fornece um bom direcionamento para a escolha dos métodos de previsão. Isso porque com o passar dos anos, diversos métodos de previsão foram surgindo, e assim a classificação proposta tornou-se obsoleta. Pode-se concluir, portanto, que atualmente não há na literatura nenhuma metodologia de classificação robusta o suficiente para auxiliar os pesquisadores da área na escolha do método de previsão para seus dados.

Por outro lado, o exercício de aplicar e comparar diversos métodos de previsão nos fornece diversas conclusões importantes. Em primeiro lugar, fica evidente que nenhum método de previsão é preponderante perante os demais. Isso porque os métodos com maior quantidade de vitórias “ganharam” em no máximo 30% da quantidade total de séries utilizadas. Mesmo os

métodos mais tradicionais e intuitivamente “ruins” são capazes de superar métodos mais robustos em determinada quantidade de séries. Em termos práticos, isso significa que é aconselhável se utilizar um conjunto de métodos de previsão ao invés de apenas um, principalmente quando o conjunto de dados a ser previsto apresenta os mais diversos comportamentos de demanda.

Em segundo lugar, destaca-se a importância de realizar um bom planejamento da previsão em termos de estratégia e métrica de erro a serem utilizados. Os resultados mostraram que é preferível utilizar a estratégia 1 (prever n vezes 1 passo à frente) do que a estratégia 3 (prever 1 vez n passos à frente), pois ela gera menor erro de previsão. Recomenda-se também escolher a métrica de erro com bastante critério, pois a escolha desta impacta diretamente na interpretação dos métodos vencedores.

Em terceiro lugar, a análise dos resultados deixa evidente porque obter um método de classificação universal é um grande desafio. Ao aumentar a quantidade de métodos de previsão, métrica de erro e estratégias utilizadas, aumenta-se consideravelmente a complexidade de análise e interpretação dos resultados. É necessário buscar novas abordagens de classificação e explorar outras características, a fim de que se possa evoluir no objetivo de construir uma metodologia de classificação universal.

Por fim, acredita-se que este trabalho tenha trazido algumas contribuições com a literatura ao consolidar os conhecimentos existentes, aplicar uma gama considerável de métodos e indicadores de desempenho em um conjunto de dados novo, e também ao explorar alguns conceitos que não são usualmente explorados. Este é apenas um primeiro passo na direção da descoberta de lógicas mais profundas que possam promover a construção da metodologia almejada.

6.1. TRABALHOS FUTUROS

Visando a continuidade desta linha de pesquisa, serão sugeridas a seguir três frentes de desenvolvimento. Em primeiro lugar, sugere-se ampliar a quantidade de métodos de previsão considerados, focando principalmente na busca por métodos de previsão híbridos, os quais tem se mostrado altamente competitivos em termos de qualidade de previsão. Em janeiro de 2019, ocorreu a quarta edição da competição mundial de previsão organizado pelo pesquisador *Spyros Makridakis* (*M4 Forecasting Competition*), a qual motivou o desenvolvimento e a divulgação de 61 novos métodos de previsão e a aplicação em 100.000 séries de dados (MAKRIDAKIS,

2020). A maioria destes métodos, bem como a massa de dados utilizada na competição encontram-se disponíveis no repositório online gratuito GitHub.

Em segundo lugar, é preciso explorar outras características além do CV^2 e do ADI que possam compor uma nova metodologia de classificação, pois é possível que novas características não pensadas e/ou testadas possam contribuir para este desafio. Além disso, podem ser utilizadas novas técnicas, como por exemplo algoritmos de aprendizagem de máquina e/ou inteligência artificial que podem satisfazer o objetivo pretendido.

Por fim, sugere-se que os métodos utilizados neste trabalho sejam integrados a políticas de reposição de estoque com o intuito de simular o funcionamento completo do sistema de gestão de estoques. Essa análise integrada é particularmente interessante pois permite realizar uma análise financeira (calcular o custo de stock-out e volume médio de estoque), contribuindo positivamente na escolha dos métodos de previsão.

REFERÊNCIAS

- ARMSTRONG, B. J. S.; COLLOPY, F. **Error Measures For Generalizing About Forecasting Methods: Empirical Comparisons**. *International Journal of Forecasting*, v. 8, p. 69–80, 1992.
- BABILONI, E. *et al.* **Demand categorisation, forecasting, and inventory control for intermittent demand items**. *South African Journal of Industrial Engineering*, v. 21, n. 2, p. 115–130, 2010.
- BACCHETTI, A.; SACCANI, N. **Spare parts classification and demand forecasting for stock control: Investigating the gap between research and practice**. *Omega*, v. 40, n. 6, p. 722–737, 2012.
- BOWERMAN, B. L.; O'CONNEL, R. T. **Forecasting, time series and regression: An applied approach**. *International Journal of Forecasting*, 2004.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 5th. ed.
- BOYLAN, J. E.; SYNTETOS, A. A. **Forecasting for Inventory Management of Service Parts**. *Complex System Maintenance Handbook*. 1th. ed. Cincinnati: Springer, 2008. p. 479–508.
- BOYLAN, J. E.; SYNTETOS, A. A.; KARAKOSTAS, G. C. **Classification for forecasting and stock control: A case study**. *Journal of the Operational Research Society*, v. 59, n. 4, p. 473–481, 2008.
- CHENG, C. Y.; CHIANG, K. L.; CHEN, M. Y. **Intermittent Demand Forecasting in a Tertiary Pediatric Intensive Care Unit**. *Journal of Medical Systems*, v. 40, n. 10, 2016.
- CROSTON, J. D. **Forecasting and stock control for intermittent demands**. *Operational Research Quarterly*, v. 3, n. 23, p. 289–303, 1972.
- EAVES, A. H. C. **Forecasting for the Ordering and Stock-Holding of Consumable Spare Parts**. Tese de Doutorado. Department of Management Science. Lancaster University, 2002.
- EAVES, A. H. C.; KINGSMAN, B. G. **Forecasting for the ordering and stock-holding of spare parts**. *Journal of the Operational Research Society*, v. 55, n. 4, p. 431–437, 2004.
- EHLERS, R. S. **Análise de Séries Temporais**. Departamento de Estatística, UFPR. Disponível em <http://leg.est.ufpr.br/~ehlers/notas>. 2005.
- FILDES, R. **The evaluation of extrapolative forecasting methods**. *International Journal of Forecasting*, v. 8, p. 81–98, 1992.
- GHOBBAR, A. A. **Forecasting Intermittent Demand for Aircraft Spare Parts**. *Journal of Aircraft*, v. 41, n. 3, 2004.
- GUTIERREZ, R. S.; SOLIS, A. O.; MUKHOPADHYAY, S. **Lumpy demand forecasting using neural networks**. *International Journal of Production Economics*, v. 111, p. 409–420, 2008.

HANKE, J. E.; REITSCH, A. G. **Business forecasting**. 5th. ed. Englewood Cliffs, NJ: Prentice-Hall, 1995.

HAYKIN, S. S. **Redes Neurais**. 2ed. Bookman, 2001.

HEINECKE, G.; SYNTETOS, A. A.; WANG, W. **Forecasting-based SKU classification**. International Journal of Production Economics, v. 143, n. 2, p. 455–462, 2013.

HOOVER, J. **Measuring forecast accuracy: omissions in today's forecasting engines and demand-planning software**. International Journal of Applied Forecasting, v. 4, p. 32–35, 2006.

HYNDMAN, R. J.; KOEHLER, A. B. **Another look at measures of forecast accuracy**. International Journal of Forecasting, v. 22, p. 679–688, 2006.

KAMPEN, T. J. VAN; AKKERMAN, R.; PIETER, D. **SKU classification : a literature review and conceptual framework**. International Journal of Operations & Production Management, Vol. 32 Iss 7 pp. 850 - 876. 2012.

KENNEY, J. F.; KEEPING, E. S. **Linear Regression and Correlation**. 3rd. ed. Princeton, NJ: Van Nostrand, 1962.

KOSTENKO, A. V.; HYNDMAN, R. J. **A note on the categorization of demand patterns**. Journal of the Operational Research Society, 57(10), p. 1256–1257, 2006.

KOURENTZES, N. **On intermittent demand model optimisation and selection**. International Journal of Production Economics, v. 156, p. 180–190, 2014.

LISBOA, J. V; GOMES, C. F. **Gestão de Operações: 3ª Edição Revista e Atualizada**. Vida Economica Editorial, 2018.

MAKRIDAKIS, S. **Accuracy measures: theoretical and practical concerns**. International Journal of Forecasting, v. 9, n. 4, p. 527–529, 1993.

MAKRIDAKIS, S.; SPILIOTIS, E.; ASSIMAKOPOULOS, V. **The M4-competiton: 100.000 times series and 61 forecasting methods**. International Journal of Forecasting, v.36, p.54-74, 2020.

MAKRIDAKIS, S.; HIBON, M. **The M3-competition: Results, conclusions and implications**. International Journal of Forecasting, v. 16, p. 451–476, 2000.

MAKRIDAKIS, S.; WELLWRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications**. 3rd. ed. New York. 1997

MARQUARDT, D. W. **An Algorithm for Least-Squares Estimation of Nonlinear Parameters**. Journal of the Society for Industrial and Applied Mathematics, Philadelphia: University City Science Center, V.11, N. 2, p. 431-441. 1963.

MEDEIROS, F. S. B.; BIANCHI, R. C. **The application of the method in Linear Regression Demand Seasonal Products: A case study**. Disciplinarum Scientia. Série: Ciências Sociais Aplicadas, v. 5, n. 1, p. 35–53, 2009.

- MIRANDA, I. P. H. **Comparação de diferentes métodos de previsão em séries temporais com valores disprepantes**. Universidade Federal de Juiz de Fora. Departamento de Estatística. Monografia. 2014.
- MONTGOMERY, D.; JENNINGS, C. **Introduction to Time Series Analysis and Forecasting**. Hoboken, New Jersey: Wiley & Sons, Inc., 2008.
- MORETTIN, P. A.; TOLOI, C. M. DE C. **Previsão de séries temporais**. 2a edição 2006
- NETO, A. C. **Análise de Séries Temporais**. Universidade Federal do Paraná. Notas de Aula. 2004
- PEINADO, J.; GRAEML, A. R. **Administração da Produção (Operações Industriais e de Serviços)**. 1th. ed. Curitiba. 2007
- PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: modelos & previsões**. Elsevier, 2004.
- PRESTWICH, S. D. *et al.* **Forecasting intermittent demand by hyperbolic-exponential smoothing**. International Journal of Forecasting, v. 30, n. 4, p. 928–933, 2014.
- REGO, J. R. DO; MESQUITA, M. A. DE. **Demand forecasting and inventory control: A simulation study on automotive spare parts**. International Journal of Production Economics, 2014.
- SCARPIN, C. T. **Uma metodologia para a previsão de demanda de produtos utilizando Redes Neurais Artificiais de Funções de Bases Radiais Modificadas e uma proposta de logística de reposição**. Tese de Doutorado. Universidde Federal do Paraná, 2012.
- SHALE, E. A.; BOYLAN, J. E.; JOHNSTON, F. R. **Forecasting for intermittent demand : the estimation of an unbiased average**. Journal of the Operational Research Society p. 588–592, 2006.
- SHUMWAY, R. H.; STOFFER, D. S. **Time Series Analysis and Its Applications: With R Examples**. Springer, 2011.
- SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais**. São Paulo: Artliber, 2010.
- SYNTETOS, A. A. **Forecasting of Intermittent Demand**. Tese de Doutorado. Buckinghamshire Chilterns University College-Brunel University, UK., 2001.
- SYNTETOS, A. A.; BOYLAN, J. E. **On the bias of intermittent demand estimates**. International Journal of Production Economics. v. 71, p. 457–466, 2001.
- SYNTETOS, A. A.; BOYLAN, J. E. **The accuracy of intermittent demand estimates**. International Journal of Forecasting. v. 21, p. 303–314, 2005.
- SYNTETOS, A. A.; BOYLAN, J. E. **On the variance of intermittent demand estimates**. International Journal of Production Economics, v. 128, n. 2, p. 546–555, 2010.

SYNTETOS, A. A.; KEYES, M.; BABAI, M. Z. **Demand categorisation in a European spare parts logistics network**. International Journal of Operations and Production Management, v. 29, n. 3, p. 292–316, 2009.

TEUNTER, R. H.; SYNTETOS, A. A.; BABAI, M. Z. **Intermittent demand : Linking forecasting to inventory obsolescence**. European Journal of Operational Research, v. 214, n. 3, p. 606–615, 2011.

WILLEMAIN, T. R.; SMART, C. N.; SCHWARZ, H. F. **A new approach to forecasting intermittent demand for service parts inventories**. International Journal of Forecasting, v. 20, p. 375–387, 2004.

WILLIAMS, T. M. **Stock Control with Sporadic and Slow-Moving Demand**. Journal of the Operational Research Society, v. 35, n. 10, p. 939–948, 1984.

XAVIER, J. M. N. **Análise e Previsão de Séries Temporais com Modelos ARIMA e Análise Espectral Singular**. Dissertação de Mestrado. Departamento de Bioestatística e Biometria. Universidade Aberta, 2016.

APÊNDICES

APÊNDICE A – Quantidade Geral de Vitórias – todos os indicadores de desempenho Gráficos 15, 16 e 17

GRÁFICO 15 - QUANTIDADE GERAL DE VITÓRIAS TODOS OS IDS (ESTRATÉGIA = 1)

Método	.MAEMean	.MASE	.MSE	GRMSE	MAE	MAPE	MdAPE	ME	RMSE	sMAPE	sMdAPE	Total
Naive	439	437	670	1292	766	279	295	719	673	373	562	6505
TLSaz	554	553	565	367	550	406	465	309	565	549	453	5336
RBF	443	443	461	382	443	322	390	502	459	441	396	4682
MMS	296	290	530	613	541	228	267	554	530	304	286	4439
Arima	411	410	442	469	416	277	318	407	440	387	316	4293
TSB	218	213	398	504	394	114	181	419	401	178	192	3212
TL	280	279	298	364	319	178	280	301	295	304	277	3175
SES	213	205	421	439	347	128	215	372	354	182	221	3097
SBJ	331	324	284	298	321	275	218	304	288	212	218	3073
RBFT	266	265	258	299	268	177	280	268	258	304	277	2920
SBA	318	304	260	244	283	265	237	281	270	224	226	2912
Croston	204	196	208	185	187	140	183	242	211	189	200	2145
HES	199	189	195	206	185	128	180	253	198	193	202	2128
SY	204	197	204	191	190	144	173	232	210	190	191	2126
Bootstrap	27	27	82	78	79	9	43	116	82	75	59	677

(a) TE = 0%

Método	.MAEMean	.MASE	.MSE	GRMSE	MAE	MAPE	MdAPE	ME	RMSE	sMAPE	sMdAPE	Total
Naive	948	703	792	1341	970	673	587	738	923	941	1106	9722
MMS	900	597	649	658	780	695	604	579	804	972	882	8120
TLSaz	937	779	648	412	722	684	712	361	741	1023	950	7969
TSB	989	631	602	577	710	677	583	468	756	1038	936	7967
SES	1001	627	606	511	660	680	607	411	706	1043	944	7796
RBF	896	660	560	445	597	645	652	536	650	973	923	7537
SBJ	947	732	504	443	695	824	551	400	633	867	761	7357
Arima	899	645	531	515	587	609	607	443	645	940	886	7307
SBA	937	715	487	388	651	826	550	398	614	877	768	7211
HES	937	602	425	287	509	681	551	320	584	1029	913	6838
Croston	928	609	431	273	517	710	558	308	591	998	884	6807
SY	925	602	425	276	513	715	549	303	587	994	881	6770
TL	758	520	394	413	494	524	550	352	498	847	846	6196
RBFT	744	505	353	349	443	522	550	319	459	847	846	5937
Bootstrap	32	31	84	78	82	14	58	121	87	127	97	811

(b) TE = 5%

FONTE: A autora (2019).

GRÁFICO 16 - QUANTIDADE GERAL DE VITÓRIAS TODOS OS IDS (ESTRATÉGIA = 2)

Método	.MAEMean	.MASE	.MSE	GRMSE	MAE	MAPE	MdAPE	ME	RMSE	sMAPE	sMdAPE	Total
Naive	398	395	608	1502	742	229	315	1291	608	229	532	6849
TLSaz	607	604	647	366	602	491	421	183	647	976	429	5973
MMS	310	306	540	877	558	228	287	565	540	339	416	4966
RBF	399	401	450	307	396	285	373	371	450	758	340	4530
Arima	378	377	423	599	384	279	361	399	421	497	360	4478
TSB	219	206	447	620	448	101	212	478	429	341	199	3700
TL	311	304	334	359	341	217	287	215	333	614	274	3589
RBFT	302	295	292	292	295	216	287	180	294	663	273	3389
SES	192	186	380	489	343	96	207	431	306	475	203	3308
SBJ	314	305	272	218	304	267	197	223	281	526	191	3098
SBA	283	275	231	187	246	253	203	210	243	540	194	2865
Croston	191	181	199	176	174	127	189	223	207	556	179	2402
SY	202	188	191	176	182	124	181	217	197	549	173	2380
HES	170	159	164	174	154	90	178	215	170	550	173	2197
Bootstrap	23	23	85	66	75	4	34	86	85	407	49	937

(a) TE = 0%

Método	.MAEMean	.MASE	.MSE	GRMSE	MAE	MAPE	MdAPE	ME	RMSE	sMAPE	sMdAPE	Total
Naive	793	525	680	1533	861	519	570	1331	747	591	1029	9199
TLSaz	913	830	744	416	767	788	717	203	847	1458	940	8718
TSB	977	558	633	681	721	642	608	527	771	1138	930	8186
MMS	833	514	648	918	717	596	580	585	748	913	996	8048
RBF	904	604	553	350	563	613	690	395	659	1312	936	7579
SES	925	477	516	547	578	594	600	472	632	1259	912	7512
Arima	866	585	521	635	545	597	646	424	630	1001	922	7372
SBJ	968	646	478	321	611	863	535	287	636	1218	774	7337
SBA	943	616	462	289	552	865	531	279	611	1236	773	7157
Croston	946	525	379	249	444	668	594	272	536	1376	897	6886
SY	950	525	378	249	450	670	588	266	538	1370	899	6883
TL	810	554	435	397	523	571	548	235	571	1183	841	6668
HES	917	480	353	247	409	634	580	262	507	1338	904	6651
RBFT	803	546	393	331	479	571	548	201	532	1232	840	6476
Bootstrap	26	26	87	67	77	5	42	89	91	453	74	1037

(b) TE = 5%

FONTE: A autora (2019).

GRÁFICO 17 - QUANTIDADE GERAL DE VITÓRIAS TODOS OS IDS (ESTRATÉGIA = 3)

Método	.MAEMean	.MASE	.MSE	GRMSE	MAE	MAPE	MdAPE	ME	RMSE	sMAPE	sMdAPE	Total
Arima	860	859	1045	812	1023	645	646	972	1044	786	685	9377
RBF	783	776	883	619	850	546	595	870	883	792	611	8208
TLSaz	694	692	669	493	700	521	555	430	668	699	563	6684
Bootstrap	322	322	370	1252	419	266	398	815	370	300	558	5392
TL	316	305	362	372	335	223	273	295	359	308	302	3450
RBFT	294	288	312	441	333	183	292	311	308	274	289	3325

(a) TE = 0%

Método	.MAEMean	.MASE	.MSE	GRMSE	MAE	MAPE	MdAPE	ME	RMSE	sMAPE	sMdAPE	Total
Arima	1330	1113	1151	884	1238	961	950	1054	1267	1363	1216	12527
RBF	1248	1020	998	701	1065	849	893	938	1123	1328	1194	11352
TLSaz	1142	931	792	569	944	837	819	593	945	1239	1135	9946
TL	976	693	584	513	727	675	677	595	751	1101	1041	8333
RBFT	936	665	553	552	701	677	665	603	730	1022	1008	8112
Bootstrap	494	407	408	1285	506	378	528	876	438	464	869	6653

(b) TE = 5%


FONTE: A autora (2019).

APÊNDICE B – Quantidade de Vitórias por Método de Previsão e Tipo de Série


ID = MAE:Mean, TE = 0% (Gráficos 18, 19 e 20)

GRÁFICO 18 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAE:Mean, TE = 0%, ESTRATÉGIA = 1)

Classificação de SB ■ Errática ■ Lumpy ■ Slow-Moving ■ Smooth




(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

GRÁFICO 19 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 0%, ESTRATÉGIA = 2)



(a) Visualização por Método




(b) Visualização por Classificação de S&B


FONTE: A autora (2019).

GRÁFICO 20 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 0%, ESTRATÉGIA = 3)

Classificação de SB ● Errática ● Lumpy ● Slow-Moving ● Smooth



(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).


ID = MSE, TE = 0% (Gráficos 21, 22 e 23)

GRÁFICO 21 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 0%, ESTRATÉGIA = 1)

Classificação de SB ● Errática ● Lumpy ● Slow-Moving ● Smooth




(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

GRÁFICO 22 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 0%, ESTRATÉGIA = 2)




(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

GRÁFICO 23 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 0%, ESTRATÉGIA = 3)



(a) Visualização por Método




(b) Visualização por Classificação de S&B


FONTE: A autora (2019).

ID = MASE, TE = 5% (Gráficos 24, 25 e 26)

GRÁFICO 24 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 5%, ESTRATÉGIA = 1)




(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

GRÁFICO 25 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 5%, ESTRATÉGIA = 2)




(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

GRÁFICO 26 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MASE, TE = 5%, ESTRATÉGIA = 3)



(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).


ID = MAE:Mean, TE = 5% (Gráficos 27, 28 e 29)

GRÁFICO 27 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAE:Mean, TE = 5%, ESTRATÉGIA = 1)

Classificação de SB: Errática Lumpy Slow-Moving Smooth




(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

GRÁFICO 28 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 5%, ESTRATÉGIA = 2)




(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

GRÁFICO 29 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MAEMEAN, TE = 5%, ESTRATÉGIA = 3)



(a) Visualização por Método




(b) Visualização por Classificação de S&B


FONTE: A autora (2019).

ID = MSE, TE = 5% (Gráficos 30, 31 e 32)

GRÁFICO 30 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 5%, ESTRATÉGIA = 1)



(a) Visualização por Método




(b) Visualização por Classificação de S&B


FONTE: A autora (2019).

GRÁFICO 31 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 5%, ESTRATÉGIA = 2)

Classificação de SB ● Errática ● Lumpy ● Slow-Moving ● Smooth



(a) Visualização por Método




(b) Visualização por Classificação de S&B


FONTE: A autora (2019).

GRÁFICO 32 - QUANTIDADE DE VITÓRIAS POR MÉTODO E TIPO DE SÉRIE (ID = MSE, TE = 5%, ESTRATÉGIA = 3)

Classificação de SB ● Errática ● Lumpy ● Slow-Moving ● Smooth



(a) Visualização por Método




(b) Visualização por Classificação de S&B

FONTE: A autora (2019).

APÊNDICE C – Box Plot do Erro de Previsão por Método e Tipo de Série


ID = MAE:Mean (Gráficos 33, 34 e 35)

GRÁFICO 33 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MAE:MEAN, ESTRATÉGIA = 1)



FONTE: A autora (2019).

GRÁFICO 34 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MAE:MEAN, ESTRATÉGIA = 2)



FONTE: A autora (2019).


GRÁFICO 35 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = MAE:MEAN, ESTRATÉGIA = 3)



FONTE: A autora (2019).


ID = RMSE (Gráficos 36, 37 e 38)

GRÁFICO 36 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 1)



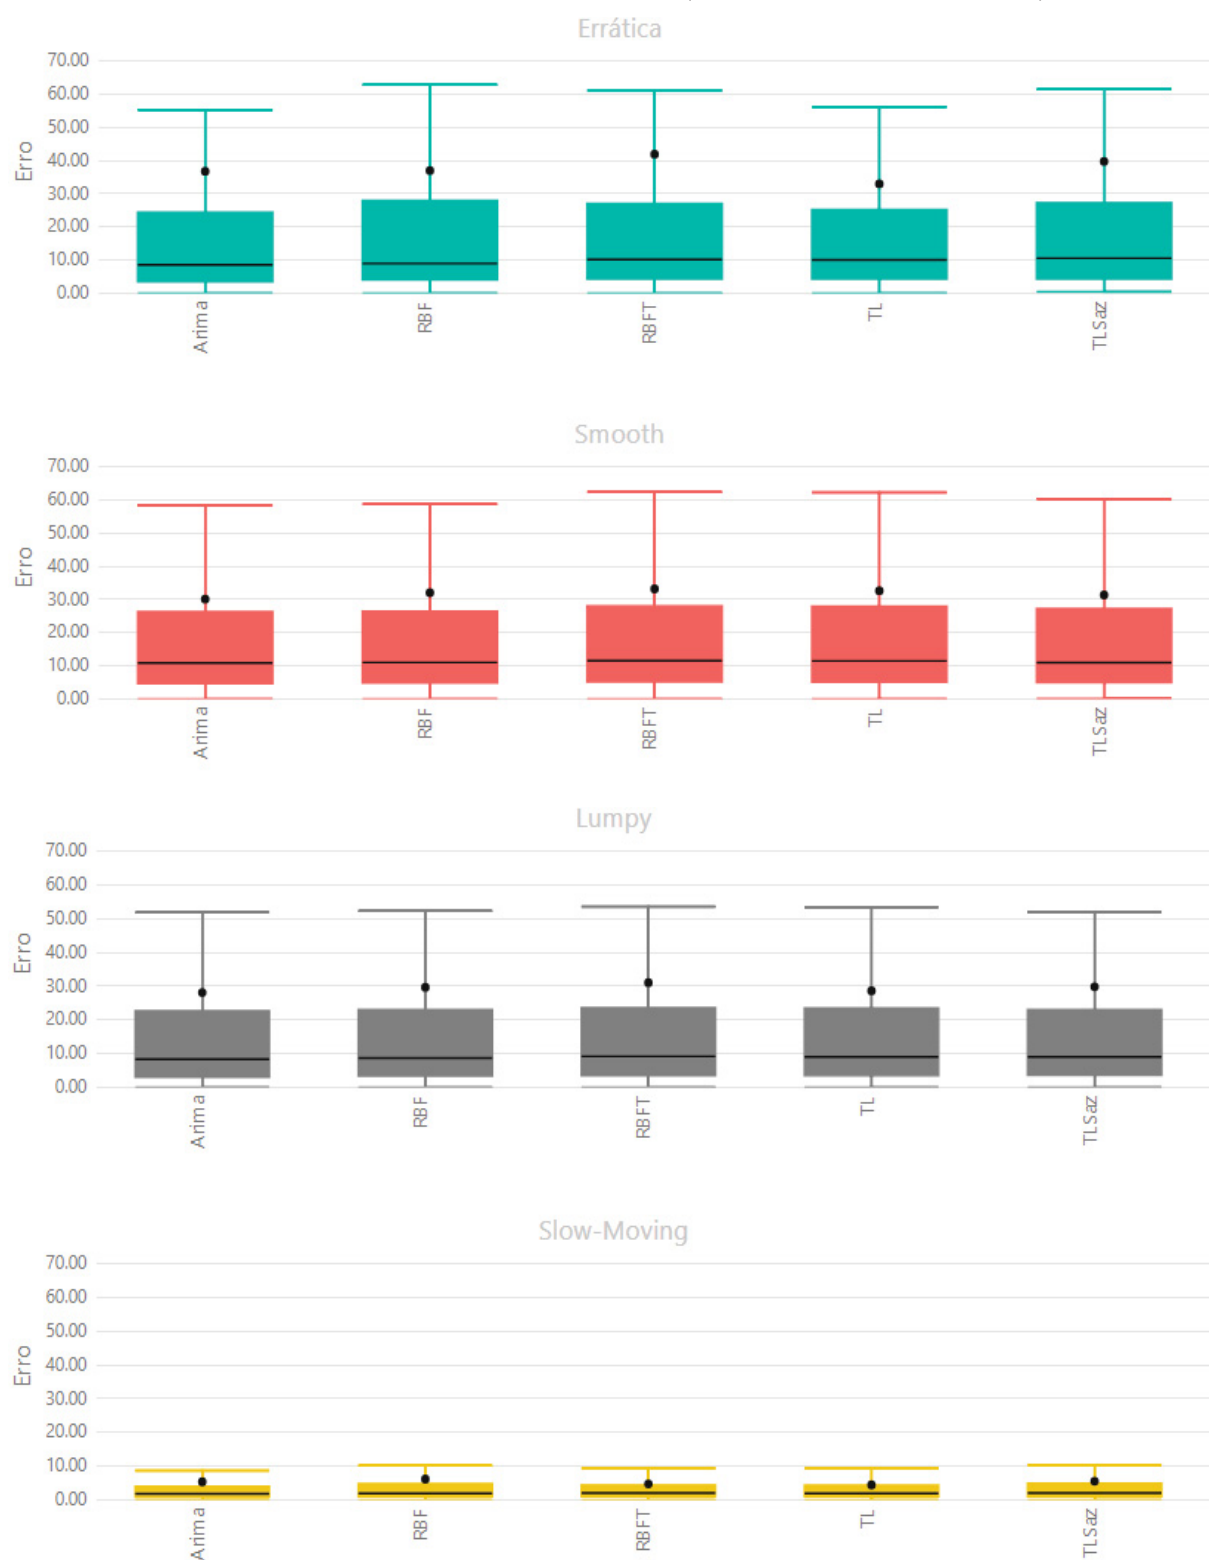
FONTE: A autora (2019).

GRÁFICO 37 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 2)



FONTE: A autora (2019).

GRÁFICO 38 - BOXPLOT DO ERRO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 3)



FONTE: A autora (2019).

APÊNDICE D – Erro de Previsão por Método e Tipo de Série – Tabelado

ID = MAE:Mean (Gráficos 39, 40 e 41)

GRÁFICO 39 - ERRO TABELADO POR TIPO DE SÉRIE (ID = MAEMEAN, ESTRATÉGIA = 1)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
TSB	1,7	0,10	0,4	0,63	0,9	1,70
HES	1,7	0,11	0,4	0,63	0,9	1,60
SES	1,7	0,08	0,4	0,63	1,0	1,78
Croston	1,7	0,11	0,4	0,64	0,9	1,58
SY	1,6	0,11	0,4	0,64	0,9	1,59
MMS	1,6	0,09	0,5	0,66	1,0	1,82
SBA	1,3	0,10	0,5	0,67	0,9	1,49
SBJ	1,3	0,10	0,5	0,68	0,9	1,49
RBF	5,0	0,12	0,5	0,69	1,2	2,28
Arima	2,4	0,05	0,5	0,69	1,0	1,86
Naive	1,7	0,08	0,5	0,70	1,0	1,82
TL	2,2	0,09	0,5	0,70	1,1	2,10
RBFT	2,2	0,09	0,5	0,71	1,2	2,28
TLSaz	2,4	0,11	0,5	0,77	1,3	2,53

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
MMS	2,7	0,18	0,6	0,89	1,4	2,44
Arima	2,3	0,21	0,6	0,89	1,5	2,90
RBF	5,3	0,19	0,7	0,89	1,9	3,71
Croston	1,7	0,17	0,7	0,92	1,2	1,96
SY	1,7	0,12	0,7	0,92	1,2	1,98
SBA	1,4	0,27	0,8	0,93	1,1	1,56
HES	2,1	0,17	0,7	0,94	1,3	2,21
SBJ	1,3	0,27	0,7	0,94	1,0	1,44
TL	1,9	0,17	0,7	0,95	1,6	3,00
SES	2,5	0,29	0,6	0,96	1,1	1,73
RBFT	2,1	0,17	0,7	0,96	1,7	3,30
TSB	2,7	0,10	0,7	0,96	1,1	1,76
Naive	2,7	0,21	0,7	1,00	1,0	1,45
TLSaz	2,4	0,17	0,7	1,07	2,1	4,20

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	0,9	0,05	0,3	0,44	0,7	1,22
TSB	1,4	0,06	0,3	0,44	0,7	1,22
MMS	1,1	0,03	0,3	0,45	0,7	1,25
HES	1,5	0,06	0,3	0,45	0,7	1,22
Croston	1,4	0,06	0,3	0,45	0,7	1,21
SY	1,4	0,06	0,3	0,45	0,7	1,21
TLSaz	1,2	0,04	0,3	0,45	0,7	1,33
RBF	1,3	0,03	0,3	0,46	0,7	1,28
Arima	1,1	0,04	0,3	0,46	0,7	1,22
RBFT	1,2	0,07	0,3	0,46	0,7	1,29
TL	1,2	0,07	0,3	0,46	0,7	1,29
SBJ	1,1	0,08	0,3	0,47	0,7	1,20
SBA	1,1	0,08	0,3	0,47	0,7	1,20
Naive	1,0	0,03	0,3	0,49	0,8	1,46

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	1,1	0,10	0,5	0,78	1,1	2,01
Croston	1,0	0,13	0,6	0,80	1,1	1,79
SY	1,0	0,13	0,6	0,81	1,1	1,86
HES	1,1	0,13	0,6	0,81	1,2	2,03
RBF	1,4	0,11	0,6	0,84	1,4	2,60
SBA	0,9	0,19	0,6	0,84	1,0	1,57
MMS	1,1	0,13	0,6	0,84	1,2	2,07
RBFT	1,1	0,08	0,6	0,85	1,2	2,08
TL	1,1	0,08	0,6	0,85	1,1	1,99
SBJ	1,0	0,19	0,7	0,85	1,0	1,51
TSB	1,1	0,12	0,6	0,86	1,2	2,03
TLSaz	1,2	0,13	0,6	0,87	1,2	2,05
SES	1,1	0,00	0,6	0,90	1,1	1,81
Naive	1,2	0,00	0,6	1,00	1,1	1,93

FONTE: A autora (2019).

GRÁFICO 40 - ERRO TABELADO POR TIPO DE SÉRIE (ID = MAEMEAN, ESTRATÉGIA = 2)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SBA	1,1	0,07	0,4	0,57	0,8	1,38
SY	1,4	0,09	0,4	0,58	0,9	1,57
Croston	1,4	0,09	0,4	0,58	0,9	1,57
SBJ	1,1	0,07	0,4	0,58	0,8	1,39
SES	1,2	0,08	0,4	0,59	0,9	1,57
TSB	1,2	0,10	0,4	0,59	0,8	1,52
HES	1,3	0,10	0,4	0,60	0,9	1,53
MMS	1,1	0,08	0,4	0,60	0,9	1,63
Naive	0,9	0,09	0,4	0,62	0,9	1,69
Arima	1,4	0,06	0,4	0,63	1,0	1,84
RBF	1,4	0,11	0,4	0,65	1,1	2,01
RBFT	2,0	0,09	0,5	0,68	1,1	2,07
TL	2,0	0,09	0,5	0,68	1,1	1,92
TLSaz	2,2	0,11	0,5	0,73	1,3	2,43

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	0,7	0,05	0,3	0,42	0,6	1,13
TSB	0,9	0,06	0,3	0,42	0,6	1,15
Croston	0,9	0,07	0,3	0,43	0,6	1,14
HES	0,9	0,07	0,3	0,43	0,6	1,14
SY	0,9	0,07	0,3	0,43	0,6	1,14
RBF	0,9	0,06	0,3	0,43	0,7	1,19
SBA	0,9	0,07	0,3	0,43	0,6	1,10
SBJ	0,9	0,07	0,3	0,43	0,6	1,10
MMS	0,7	0,04	0,3	0,44	0,7	1,18
Arima	0,8	0,04	0,3	0,44	0,7	1,18
TLSaz	1,1	0,04	0,3	0,44	0,7	1,25
RBFT	1,1	0,07	0,3	0,45	0,7	1,21
TL	1,1	0,07	0,3	0,45	0,7	1,21
Naive	0,6	0,06	0,3	0,47	0,7	1,24

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	1,7	0,19	0,6	0,80	1,4	2,66
MMS	1,9	0,17	0,6	0,87	1,4	2,54
Croston	1,4	0,14	0,6	0,87	1,3	2,29
SY	1,4	0,14	0,6	0,87	1,3	2,36
SBA	1,2	0,23	0,7	0,87	1,1	1,86
SES	1,4	0,23	0,6	0,87	1,2	2,01
SBJ	1,1	0,23	0,7	0,88	1,0	1,54
RBF	2,0	0,23	0,6	0,88	1,5	2,89
HES	1,4	0,20	0,6	0,89	1,3	2,29
RBFT	1,9	0,18	0,6	0,89	1,6	3,15
TL	1,7	0,18	0,6	0,89	1,4	2,63
TSB	1,5	0,14	0,6	0,91	1,3	2,40
Naive	1,3	0,23	0,7	0,93	1,4	2,58
TLSaz	2,1	0,17	0,7	1,09	1,9	3,76

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Croston	1,0	0,14	0,5	0,75	1,1	1,95
SY	1,0	0,14	0,5	0,76	1,1	1,96
Arima	1,0	0,13	0,5	0,77	1,2	2,12
MMS	0,9	0,10	0,5	0,77	1,2	2,10
SBA	0,9	0,19	0,6	0,78	1,1	1,89
HES	1,0	0,14	0,5	0,80	1,2	2,09
SES	0,9	0,00	0,5	0,80	1,0	1,69
TSB	1,0	0,12	0,5	0,81	1,2	2,12
RBFT	1,1	0,08	0,6	0,81	1,2	2,15
TL	1,1	0,08	0,6	0,81	1,2	2,11
SBJ	1,0	0,19	0,6	0,82	1,0	1,64
RBF	1,2	0,07	0,5	0,83	1,3	2,35
TLSaz	1,3	0,13	0,6	0,87	1,2	2,12
Naive	1,0	0,00	0,6	0,88	1,3	2,37

FONTE: A autora (2019).

GRÁFICO 41 - ERRO TABELADO POR TIPO DE SÉRIE (ID = MAEMEAN, ESTRATÉGIA = 3)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	2,3	0,09	0,5	0,67	1,0	1,81
RBF	2,6	0,10	0,5	0,68	1,2	2,21
TL	2,3	0,09	0,5	0,71	1,1	2,09
RBFT	2,4	0,08	0,5	0,72	1,2	2,14
TLsaz	2,4	0,09	0,5	0,74	1,3	2,54

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
RBF	3,6	0,25	0,7	0,92	1,8	3,51
Arima	2,8	0,11	0,6	0,93	1,4	2,52
TL	2,0	0,30	0,7	0,95	1,5	2,70
RBFT	2,0	0,26	0,7	1,00	1,6	2,86
TLsaz	2,4	0,20	0,7	1,03	2,0	3,91

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
RBF	1,2	0,05	0,3	0,46	0,7	1,24
Arima	1,2	0,04	0,3	0,46	0,7	1,26
TLsaz	1,2	0,04	0,3	0,46	0,7	1,32
TL	1,2	0,09	0,3	0,47	0,7	1,30
RBFT	1,2	0,08	0,3	0,48	0,7	1,31

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
RBF	1,2	0,06	0,6	0,81	1,2	2,08
TL	1,1	0,08	0,6	0,83	1,2	2,02
Arima	1,1	0,11	0,6	0,84	1,2	2,20
TLsaz	1,3	0,12	0,6	0,85	1,2	2,11
RBFT	1,2	0,07	0,6	0,86	1,2	2,13

FONTE: A autora (2019).

ID = MASE (Gráficos 42, 43 e 44)

GRÁFICO 42 - ERRO TABELADO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 1)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	2,3	0,40	0,8	1,03	1,6	2,96
TSB	2,3	0,39	0,8	1,03	1,6	2,85
HES	2,2	0,38	0,8	1,04	1,6	2,87
SY	2,2	0,38	0,8	1,04	1,6	2,83
Croston	2,3	0,41	0,8	1,05	1,6	2,83
MMS	2,1	0,40	0,8	1,05	1,7	2,95
SBA	1,9	0,41	0,8	1,08	1,6	2,83
SBJ	1,9	0,40	0,8	1,09	1,6	2,90
Naive	2,5	0,40	0,8	1,10	1,7	3,09
Arima	3,1	0,35	0,8	1,14	1,8	3,35
RBF	6,7	0,31	0,8	1,14	2,0	3,90
TL	2,7	0,40	0,8	1,19	2,1	4,11
RBFT	2,8	0,42	0,8	1,20	2,2	4,21
TLsaz	3,2	0,27	0,9	1,31	2,4	4,72

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	1,4	0,40	0,7	0,91	1,3	2,17
TSB	1,9	0,34	0,7	0,93	1,4	2,28
HES	1,9	0,34	0,7	0,93	1,3	2,25
Croston	1,9	0,34	0,7	0,94	1,3	2,26
SY	1,9	0,34	0,7	0,94	1,4	2,27
MMS	1,6	0,24	0,7	0,94	1,4	2,26
SBA	1,6	0,24	0,8	0,97	1,4	2,36
SBJ	1,6	0,24	0,7	0,97	1,4	2,36
Arima	1,6	0,28	0,8	0,98	1,4	2,34
RBF	2,0	0,30	0,7	0,98	1,4	2,44
TL	1,7	0,42	0,8	0,98	1,5	2,54
RBFT	1,7	0,42	0,8	0,98	1,5	2,55
TLsaz	1,7	0,12	0,7	0,98	1,5	2,71
Naive	1,6	0,40	0,8	0,99	1,5	2,64

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SBJ	1,4	0,40	0,7	0,97	1,4	2,47
SES	2,7	0,40	0,7	0,97	1,5	2,79
MMS	2,6	0,40	0,7	0,98	1,6	2,89
TSB	2,8	0,40	0,7	0,99	1,5	2,62
Arima	2,7	0,33	0,7	1,01	1,5	2,79
SBA	1,5	0,40	0,7	1,03	1,4	2,55
Croston	1,9	0,40	0,7	1,05	1,6	2,90
SY	1,9	0,39	0,7	1,05	1,6	2,88
HES	2,1	0,38	0,7	1,06	1,6	2,97
TL	2,0	0,45	0,8	1,06	1,7	3,09
Naive	3,0	0,40	0,7	1,08	1,6	2,96
RBF	4,6	0,37	0,8	1,08	1,9	3,52
RBFT	2,1	0,45	0,8	1,11	1,8	3,41
TLsaz	2,5	0,35	0,8	1,18	2,3	4,55

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
TSB	1,2	0,40	0,7	0,92	1,4	2,52
Arima	1,2	0,27	0,7	0,93	1,4	2,38
MMS	1,2	0,34	0,7	0,93	1,4	2,44
HES	1,2	0,41	0,7	0,93	1,4	2,40
SES	1,3	0,40	0,7	0,94	1,4	2,55
TL	1,2	0,42	0,7	0,94	1,5	2,57
RBFT	1,3	0,44	0,7	0,95	1,5	2,67
SY	1,2	0,43	0,7	0,95	1,4	2,35
Croston	1,2	0,43	0,7	0,95	1,4	2,35
SBA	1,2	0,38	0,7	0,95	1,4	2,38
SBJ	1,2	0,40	0,7	0,97	1,4	2,38
Naive	1,4	0,40	0,7	1,00	1,6	2,88
TLsaz	1,4	0,40	0,7	1,01	1,6	2,80
RBF	1,6	0,36	0,7	1,01	1,6	2,80

FONTE: A autora (2019).

GRÁFICO 43 - ERRO TABELADO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 2)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	1,7	0,42	0,8	0,98	1,2	1,78
SBA	1,5	0,32	0,8	0,99	1,3	1,95
TSB	1,7	0,40	0,8	0,99	1,2	1,81
Croston	1,8	0,41	0,8	0,99	1,3	1,90
HES	1,7	0,39	0,8	0,99	1,2	1,86
SY	1,8	0,39	0,8	0,99	1,2	1,87
SBJ	1,5	0,32	0,8	1,00	1,3	1,98
Naive	1,3	0,80	0,9	1,01	1,2	1,68
MMS	1,5	0,44	0,8	1,04	1,3	2,13
Arima	1,8	0,30	0,9	1,05	1,4	2,26
RBF	1,8	0,37	0,9	1,09	1,5	2,51
TL	2,4	0,40	0,8	1,14	1,9	3,48
RBFT	2,4	0,44	0,8	1,15	1,9	3,50
TLSaz	2,9	0,30	0,8	1,27	2,2	4,21

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	1,2	0,42	0,8	0,98	1,1	1,60
TSB	1,3	0,30	0,8	0,98	1,1	1,68
Croston	1,3	0,34	0,8	0,98	1,2	1,69
SY	1,3	0,34	0,8	0,98	1,2	1,69
HES	1,3	0,34	0,8	0,98	1,2	1,69
SBA	1,3	0,24	0,8	0,94	1,2	1,77
SBJ	1,3	0,24	0,8	0,94	1,2	1,77
TLSaz	1,6	0,12	0,7	0,95	1,4	2,49
TL	1,6	0,42	0,8	0,96	1,4	2,23
Arima	1,3	0,34	0,8	0,96	1,2	1,87
RBFT	1,6	0,42	0,8	0,96	1,4	2,24
RBF	1,3	0,30	0,8	0,96	1,2	1,93
MMS	1,2	0,36	0,8	0,97	1,2	1,85
Naive	1,1	0,80	0,9	1,01	1,2	1,58

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	1,4	0,40	0,8	0,94	1,2	1,76
Croston	1,4	0,40	0,8	0,94	1,4	2,31
SBA	1,3	0,40	0,7	0,94	1,3	2,13
SY	1,4	0,40	0,7	0,95	1,4	2,28
TSB	1,6	0,52	0,8	0,95	1,2	1,90
HES	1,4	0,50	0,8	0,95	1,3	2,20
Arima	1,8	0,49	0,8	0,97	1,3	2,10
Naive	1,4	0,80	0,8	0,98	1,2	1,80
MMS	1,8	0,44	0,7	0,99	1,4	2,38
TL	1,8	0,47	0,7	1,02	1,6	2,92
RBFT	1,9	0,47	0,8	1,03	1,8	3,26
RBF	1,9	0,32	0,8	1,07	1,6	2,66
TLSaz	2,2	0,36	0,8	1,18	2,1	4,16

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	1,0	0,40	0,8	0,91	1,2	1,80
Arima	1,1	0,28	0,7	0,92	1,2	1,91
TSB	1,1	0,46	0,8	0,92	1,2	1,82
MMS	1,0	0,40	0,7	0,92	1,2	1,94
TL	1,2	0,42	0,7	0,93	1,4	2,38
RBFT	1,2	0,45	0,7	0,93	1,4	2,39
SY	1,1	0,35	0,7	0,93	1,2	1,85
Croston	1,1	0,38	0,7	0,93	1,2	1,90
SBA	1,1	0,44	0,7	0,93	1,2	1,85
HES	1,1	0,46	0,8	0,94	1,2	1,91
SBJ	1,1	0,40	0,7	0,94	1,2	1,88
TLSaz	1,5	0,40	0,7	0,96	1,5	2,68
RBF	1,2	0,37	0,7	0,96	1,3	2,12
Naive	1,1	0,80	0,9	1,00	1,2	1,72

FONTE: A autora (2019).

GRÁFICO 44 - ERRO TABELADO POR TIPO DE SÉRIE (ID = MASE, ESTRATÉGIA = 3)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	2,9	0,27	0,8	1,10	1,8	3,31
RBF	3,1	0,42	0,8	1,15	2,0	3,66
TL	2,8	0,40	0,8	1,20	2,1	4,12
RBFT	2,9	0,29	0,8	1,24	2,2	4,29
TLSaz	3,1	0,24	0,8	1,27	2,3	4,46

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	2,8	0,23	0,7	1,02	1,7	3,12
RBF	3,5	0,40	0,7	1,05	1,8	3,37
TL	2,0	0,44	0,8	1,10	1,8	3,30
RBFT	2,0	0,43	0,8	1,18	1,8	3,30
TLSaz	2,5	0,37	0,8	1,19	2,1	4,11

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	1,7	0,33	0,7	0,95	1,4	2,48
RBF	1,7	0,29	0,7	0,97	1,4	2,49
TL	1,7	0,42	0,8	0,97	1,5	2,55
TLSaz	1,7	0,12	0,7	0,99	1,5	2,73
RBFT	1,8	0,32	0,8	1,00	1,5	2,62

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
TL	1,2	0,44	0,7	0,93	1,4	2,50
RBF	1,3	0,38	0,7	0,94	1,3	2,31
Arima	1,3	0,32	0,7	0,94	1,4	2,56
RBFT	1,3	0,43	0,7	0,97	1,5	2,73
TLSaz	1,4	0,33	0,8	0,99	1,5	2,60

FONTE: A autora (2019).

ID = RMSE (Gráficos 45, 46 e 47)

GRÁFICO 45 - ERRO TABELADO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 1)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	34,5	0,00	3,0	7,32	21,8	50,17
MMS	29,6	0,00	3,1	7,46	21,5	48,92
TSB	34,4	0,00	3,2	7,67	22,3	50,88
SBA	30,5	0,10	3,3	7,75	21,8	49,69
SBJ	29,9	0,13	3,2	7,78	21,9	49,90
SY	34,4	0,27	3,2	7,81	22,7	52,03
Croston	34,4	0,37	3,2	7,83	22,7	52,00
Naive	38,5	0,00	2,9	7,86	22,5	51,91
HES	34,2	0,06	3,2	7,87	22,2	50,77
Arima	39,7	0,00	3,8	8,42	24,0	54,44
RBF	50,2	0,15	4,2	8,99	27,5	62,52
TL	32,9	0,00	4,2	9,87	24,4	54,70
RBFT	33,2	0,40	4,4	9,97	24,6	54,94
TLsaz	43,5	0,40	4,2	10,48	28,2	64,05

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	29,0	0,00	4,1	10,12	25,7	58,12
MMS	28,9	0,00	4,3	10,31	25,8	58,14
TSB	29,4	0,00	4,3	10,39	25,7	57,92
HES	29,8	0,06	4,7	10,73	26,2	58,59
Arima	30,7	0,00	4,7	10,87	26,1	58,02
SY	29,9	0,15	4,7	10,88	26,3	58,71
SBJ	30,3	0,08	4,5	10,89	26,8	60,15
RBF	42,1	0,01	4,9	10,89	26,3	58,52
Croston	29,9	0,23	4,7	10,90	26,3	58,84
SBA	30,4	0,06	4,5	10,92	26,6	59,64
Naive	31,3	0,00	4,6	10,95	27,8	62,60
TLsaz	31,4	0,24	5,1	11,07	27,3	60,74
TL	32,5	0,00	5,1	11,51	28,1	62,59
RBFT	32,5	0,27	5,1	11,53	28,1	62,53

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	8,1	0,00	0,5	1,70	5,7	13,33
SBJ	7,0	0,00	0,6	1,80	4,9	11,22
SBA	7,1	0,00	0,7	1,91	4,5	10,22
Naive	8,6	0,00	0,8	1,95	5,2	11,88
MMS	8,1	0,00	0,9	1,96	5,8	13,07
TSB	7,9	0,00	0,8	2,05	5,4	12,43
Arima	9,2	0,00	1,1	2,08	5,7	12,48
SY	7,8	0,10	0,8	2,11	5,4	12,80
Croston	7,8	0,13	0,8	2,15	5,4	12,80
TL	7,6	0,00	1,2	2,22	5,8	12,69
HES	8,1	0,00	0,9	2,37	5,9	13,44
RBFT	8,8	0,12	1,3	2,44	5,8	12,67
RBF	12,3	0,10	1,2	2,52	7,1	15,85
TLsaz	11,7	0,09	1,3	2,53	7,2	15,98

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
MMS	3,8	0,00	0,8	1,72	3,5	7,64
SBA	4,3	0,03	0,9	1,75	4,3	9,37
SES	3,9	0,00	0,8	1,75	3,6	7,65
Croston	4,3	0,08	0,9	1,76	4,2	9,15
SY	4,2	0,05	0,9	1,76	4,2	9,13
Arima	5,4	0,04	0,9	1,79	4,0	8,72
SBJ	4,2	0,00	0,9	1,83	4,3	9,37
HES	4,2	0,06	1,0	1,85	4,1	8,70
TSB	4,1	0,00	0,9	1,90	3,5	7,34
TL	4,4	0,00	1,0	1,94	4,4	9,47
Naive	4,2	0,00	0,8	1,95	3,9	8,59
RBFT	4,6	0,03	1,0	2,01	4,4	9,58
TLsaz	5,4	0,05	1,0	2,08	5,0	10,98
RBF	6,9	0,09	1,2	2,19	4,9	10,39

FONTE: A autora (2019).

GRÁFICO 46 - ERRO TABELADO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 2)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	28,9	0,00	2,9	6,43	18,5	41,81
TSB	30,0	0,00	3,1	6,64	19,1	43,12
Naive	29,7	0,00	3,0	6,78	19,6	44,43
HES	30,0	0,07	3,0	6,94	19,2	43,55
MMS	27,3	0,00	2,9	6,95	19,0	43,11
SY	30,3	0,09	3,2	7,04	20,2	45,64
SBA	27,7	0,20	3,2	7,06	20,0	45,19
Croston	30,3	0,17	3,3	7,12	20,2	45,61
SBJ	27,2	0,24	3,2	7,17	20,0	45,21
Arima	30,5	0,00	3,4	7,66	21,0	47,33
RBF	30,1	0,08	3,5	7,71	21,8	49,21
TL	30,9	0,00	4,0	9,24	22,9	51,29
RBFT	31,1	0,36	4,2	9,26	23,4	52,24
TLsaz	51,6	0,36	4,1	9,77	25,6	57,87

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	26,8	0,00	3,9	9,75	23,1	51,85
TSB	27,2	0,00	4,0	9,78	23,9	53,80
MMS	27,2	0,00	4,0	10,06	24,8	55,92
HES	27,6	0,11	4,3	10,20	24,1	53,93
RBF	28,7	0,03	4,4	10,21	24,6	54,83
Arima	28,5	0,00	4,4	10,24	23,9	53,15
Naive	29,1	0,00	4,3	10,37	24,8	55,57
TLsaz	29,8	0,24	4,8	10,58	26,1	58,00
Croston	28,2	0,31	4,6	10,62	24,7	54,83
SY	28,3	0,17	4,6	10,62	24,7	54,78
SBJ	28,5	0,19	4,5	10,63	24,7	54,91
SBA	28,5	0,13	4,5	10,70	24,5	54,50
TL	30,9	0,00	4,8	11,15	26,8	59,74
RBFT	30,9	0,25	4,9	11,21	26,8	59,68

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
SES	6,5	0,00	0,6	1,55	4,9	11,37
SBJ	6,5	0,00	0,7	1,65	4,8	10,91
TSB	6,6	0,00	0,6	1,83	4,9	11,30
Naive	6,5	0,00	0,6	1,90	4,9	11,35
SBA	6,6	0,00	0,8	1,93	4,8	10,84
Arima	7,2	0,00	0,9	1,94	5,2	11,60
HES	6,7	0,00	0,8	1,98	5,1	11,56
MMS	6,8	0,00	0,9	1,99	5,3	11,85
SY	7,0	0,16	0,9	2,00	5,0	11,14
TL	7,0	0,00	1,1	2,03	5,5	12,04
Croston	7,0	0,29	0,9	2,05	5,0	11,14
RBF	7,1	0,20	1,1	2,14	5,7	12,58
RBFT	8,1	0,11	1,2	2,19	5,6	12,03
TLsaz	10,8	0,09	1,3	2,58	6,8	15,13

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
MMS	3,4	0,00	0,7	1,59	3,5	7,58
SES	3,4	0,00	0,8	1,66	3,5	7,66
HES	3,7	0,08	0,9	1,73	3,6	7,73
Arima	4,1	0,04	0,9	1,73	3,9	8,46
SBA	3,9	0,06	0,9	1,74	4,1	8,97
SBJ	3,8	0,00	0,9	1,74	4,0	8,72
SY	3,9	0,10	1,0	1,76	3,8	8,04
Croston	3,9	0,16	1,0	1,78	3,9	8,33
TSB	3,4	0,00	0,8	1,79	3,6	7,92
TL	4,1	0,00	0,9	1,84	4,1	8,78
Naive	3,6	0,00	0,8	1,90	4,0	8,84
RBFT	4,3	0,03	0,9	1,92	4,3	9,27
TLsaz	6,6	0,05	1,0	1,99	4,7	10,13
RBF	3,8	0,08	1,1	1,99	4,2	8,95

FONTE: A autora (2019).

GRÁFICO 47 - ERRO TABELADO POR TIPO DE SÉRIE (ID = RMSE, ESTRATÉGIA = 3)

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	36,7	0,00	3,5	8,57	24,4	55,68
RBF	37,0	0,00	4,1	8,97	28,0	63,85
TL	33,0	0,00	4,3	10,08	25,2	56,52
RBFT	41,9	0,00	4,4	10,15	27,1	61,11
TLsaz	39,7	0,45	4,4	10,58	27,3	61,65

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	30,1	0,00	4,6	10,87	26,3	58,74
TLsaz	31,3	0,14	5,1	11,00	27,2	60,52
RBF	32,0	0,00	4,9	11,04	26,4	58,74
TL	32,6	0,00	5,1	11,50	27,9	62,23
RBFT	33,2	0,00	5,2	11,59	28,1	62,40

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	8,6	0,00	1,0	2,12	6,0	13,71
TL	7,5	0,00	1,2	2,32	6,0	13,07
RBF	12,6	0,00	1,2	2,34	6,5	14,50
RBFT	7,9	0,00	1,3	2,53	6,0	13,46
TLsaz	13,0	0,08	1,3	2,63	6,6	14,43

Método	Média	Mínimo	Q1	Mediana	Q3	Lim Sup
Arima	5,4	0,00	0,9	1,83	4,0	8,71
TL	4,5	0,00	1,0	1,92	4,4	9,44
RBF	6,2	0,00	1,0	1,95	4,8	10,34
TLsaz	5,5	0,03	1,1	2,02	4,9	10,75
RBFT	4,8	0,00	1,0	2,04	4,4	9,49

FONTE: A autora (2019).

APÊNDICE E – Comparação Detalhada entre as Estratégias 1 e 3

ID = MASE (Tabelas 10, 11 e 12)

TABELA 10 - QUANTIDADE DE VITÓRIAS POR MÉTODO – MASE ESTRATÉGIA 1 VENCE A 3

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	29	29	15	47	20	85	225
SES	10	22	11	36	9	56	144
TL	52	2	1	8	16	3	82
TLSaz	13	188	2	10	12	21	246
Croston	8	21	12	26	10	59	136
SBA	16	39	21	61	6	87	230
SBJ	15	44	21	63	13	82	238
HES	6	23	13	32	8	52	134
TSB	14	18	11	37	10	65	155
SY	10	24	13	26	9	55	137
Bootstrap	4	3	3	10	4	4	28
RBF	13	20	14	159	18	41	265
RBFT	50	2	1	8	16	3	80
ARIMA	20	32	14	59	20	130	275
Naive	30	30	19	94	29	136	338
Total	290	497	171	676	200	879	2713

FONTE: A autora (2019).

TABELA 11 - QUANTIDADE DE VITÓRIAS POR MÉTODO – MASE ESTRATÉGIA 3 VENCE A 1

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	1	5	19	17	6	14	62
SES	1	5	16	7	3	20	52
TL	51	18	27	16	48	12	172
TLSaz	2	218	29	15	24	16	304
Croston	2	6	13	18	1	17	57
SBA	0	8	19	19	4	19	69
SBJ	0	10	21	21	4	20	76
HES	2	4	9	22	1	17	55
TSB	2	4	14	17	2	14	53
SY	2	8	15	16	1	15	57
Bootstrap	0	0	0	1	0	0	1
RBF	2	5	35	109	10	19	180
RBFT	50	18	26	15	47	10	166
ARIMA	3	10	21	19	5	82	140
Naive	3	9	21	14	7	26	80
Total	121	328	285	326	163	301	1524

FONTE: A autora (2019).

TABELA 12 - QUANTIDADE DE EMPATES POR MÉTODO – MASE

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	4	1	0	0	5	6	16
SES	2	0	5	2	2	5	16
TL	11	0	0	0	6	4	21
TLSaz	1	7	0	1	1	0	10
Croston	0	0	0	0	0	0	0
SBA	0	0	0	0	0	0	0
SBJ	0	0	3	1	0	1	5
HES	0	0	0	0	0	0	0
TSB	0	0	4	2	0	2	8
SY	0	0	0	0	0	0	0
Bootstrap	0	0	1	0	0	0	1
RBF	0	1	0	1	0	0	2
RBFT	5	0	0	0	1	1	7
ARIMA	0	0	0	1	0	5	6
Naive	5	0	9	5	5	10	34
Total	28	9	22	13	20	34	126

FONTE: A autora (2019).

ID = MAE:Mean (Tabelas 13, 14 e 15)

TABELA 13 - QUANTIDADE DE VITÓRIAS POR MÉTODO – MAE:MEAN ESTRATÉGIA 1 VENCE A 3

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	31	29	15	46	21	85	227
SES	11	22	11	40	8	59	151
TL	51	2	1	8	13	3	78
TLSaz	14	183	2	10	14	21	244
Croston	8	21	12	26	6	63	136
SBA	17	38	24	63	7	89	238
SBJ	16	45	21	64	12	82	240
HES	6	23	13	33	8	56	139
TSB	14	17	10	38	8	65	152
SY	10	24	13	26	5	58	136
Bootstrap	4	3	3	10	4	4	28
RBF	13	21	14	156	18	41	263
RBFT	49	2	1	8	13	3	76
ARIMA	24	32	14	59	20	130	279
Naive	30	30	20	94	30	137	341
Total	298	492	174	681	187	896	2728

FONTE: A autora (2019).

TABELA 14 - QUANTIDADE DE VITÓRIAS POR MÉTODO – MAE:MEAN ESTRATÉGIA 3 VENCE A 1

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	1	5	19	17	6	16	64
SES	1	4	16	6	3	22	52
TL	48	18	27	16	47	12	168
TLSaz	2	219	29	15	26	15	306
Croston	2	6	15	18	1	19	61
SBA	0	7	19	20	4	22	72
SBJ	0	10	23	21	4	20	78
HES	2	4	11	22	1	19	59
TSB	2	4	15	18	2	17	58
SY	2	8	17	16	1	17	61
Bootstrap	0	0	0	1	0	0	1
RBF	2	5	35	105	10	19	176
RBFT	47	18	26	15	46	10	162
ARIMA	3	10	21	19	5	82	140
Naive	3	9	21	14	7	26	80
Total	115	327	294	323	163	316	1538

FONTE: A autora (2019).

TABELA 15 - QUANTIDADE DE EMPATES POR MÉTODO – MAE:MEAN

Método	TL	TLSaz	Bootstrap	RBF	RBFT	ARIMA	Total
MMS	4	1	0	3	5	6	19
SES	2	1	5	2	2	5	17
TL	13	0	0	1	9	4	27
TLSaz	1	12	0	1	0	0	14
Croston	0	0	0	0	0	0	0
SBA	0	1	0	0	0	0	1
SBJ	0	0	3	1	0	1	5
HES	0	0	0	0	0	0	0
TSB	0	0	4	3	0	2	9
SY	0	0	0	0	0	0	0
Bootstrap	0	0	1	0	0	0	1
RBF	0	0	0	10	0	1	11
RBFT	7	0	0	1	4	1	13
ARIMA	0	0	0	1	0	5	6
Naive	6	0	9	5	5	10	35
Total	33	15	22	28	25	35	158

FONTE: A autora (2019).